

CLASIFICACIÓN BÁSICA DE NEUROSEÑALES

PAULO ANDRÉS VÉLEZ ÁNGEL
HAEDERS SALDARRIAGA VILLAFañE

UNIVERSIDAD TECNOLÓGICA DE PEREIRA
FACULTAD DE CIENCIAS BÁSICAS
MAESTRÍA EN INSTRUMENTACIÓN FÍSICA
PEREIRA
2010

CLASIFICACIÓN BÁSICA DE NEUROSEÑALES

Ing. PAULO ANDRÉS VÉLEZ ÁNGEL
Ing. HAEDERS SALDARRIAGA VILLAFANE

Proyecto de grado para optar el título de Magíster en Instrumentación Física

Director:
PhD. Humberto Loaiza Correa
UNIVERSIDAD DEL VALLE

UNIVERSIDAD TECNOLÓGICA DE PEREIRA
FACULTAD DE CIENCIAS BÁSICAS
MAESTRÍA EN INSTRUMENTACIÓN FÍSICA
PEREIRA

2010

Nota de aceptación:

Aprobado por el comité curricular en cumplimiento con los requisitos exigidos por la Universidad Tecnológica de Pereira para optar el título de Magíster en Instrumentación física.

Jurado

Jurado

Director

TABLA DE CONTENIDO

1. INTRODUCCIÓN	9
2. MARCO TEÓRICO	12
2.1 INTRODUCCIÓN	12
2.2 ANTECEDENTES.....	13
2.3 SEÑALES ELECTROENCEFALOGRÁFICAS (EEG)	16
2.3.1 Delta	20
2.3.2 Theta	21
2.3.3 Alfa.....	21
2.3.4 Mu	22
2.3.5 Beta	22
2.3.6 Ram-alta	23
2.3.7 Ondas Gama	23
2.4 SISTEMAS CONTROLADOS POR EEG	23
2.5 TRANSFORMADAS MATEMÁTICAS.....	24
2.5.1 Transformadas de ventanas de Fourier.....	25
2.5.2 Wavelet	25
2.6 SISTEMAS DE RECONOCIMIENTO DE PATRONES	29
2.6.1 Sistemas de reconocimiento de patrones estadísticos	30
2.6.2 Redes neuronales artificiales (RNA)	31
2.7 MARCO CONCEPTUAL.....	32
2.8 CONCLUSIONES	33
3. DESCRIPCIÓN DE LA PLATAFORMA DE EXPERIMENTACIÓN	35
3.1 INTRODUCCIÓN	35
3.2 ETAPA DE CAPTURA DE INFORMACIÓN	35
3.3 EQUIPO DE PROCESAMIENTO	37
3.4 PROTOCOLO DE TOMA DE MUESTRAS	38
3.5 CONCLUSIONES	39
4. DESCRIPCIÓN FUNCIONAL	40
4.1 INTRODUCCIÓN	40
4.2 FORMATO DE LOS ARCHIVOS PROVENIENTES DEL EEG	40
4.3 DIAGRAMA DE BLOQUES.....	41
4.3.1 Módulo de entrenamiento	41
4.3.2 Módulo de verificación	43
4.4 FUNCIONES DE PREPROCESAMIENTO DE LA INFORMACIÓN	44
4.5 FUNCIONES DE PROCESAMIENTO DE DATOS	46
4.6 CONTROL DEL MOUSE DESDE LA APLICACIÓN	47
4.7 CONCLUSIONES	48
5. PRUEBAS Y RESULTADOS	49
5.1 INTRODUCCIÓN	49
5.2 DESCRIPCIÓN DE LAS PRUEBAS.....	49
5.3 RESULTADOS CON LA WAVELET SYM3.....	52
5.4 RESULTADOS CON LA WAVELET SYM 6.....	54
5.5 RESULTADOS CON LA WAVELET DAUBICHIES 4.....	56

5.6 RESULTADOS AL MODIFICAR LA ESTRUCTURA DE LA RED NEURONAL	57
5.7 VERIFICACIÓN CON NUEVAS MUESTRAS.....	59
5.8 COMPARACIÓN CON OTRAS TÉCNICAS.....	60
5.9 CONCLUSIONES	61
6. OBSERVACIONES.....	63
7. CONCLUSIONES GENERALES	65
8. PERSPECTIVAS FUTURAS DE TRABAJO	67
9. REFERENCIAS BIBLIOGRÁFICAS.....	68
10. ANEXOS	74

ÍNDICE DE FIGURAS

Figura 1. División funcional del cerebro.....	17
Figura 2. Ubicación de electrodos en el sistema 10-20	18
Figura 3. Onda Delta.....	21
Figura 4. Onda Theta.....	21
Figura 5. Onda Alfa	21
Figura 6. Onda Mu	22
Figura 7. Onda Beta.....	22
Figura 8. <i>Modo de descomposición de la señal (S), en que opera el análisis Wavelet. De cada descomposición se obtiene una aproximación (A) y un Detalle (D)</i>	28
Figura 9. Estructura de una red LVQ	32
Figura 10. Equipo CEEGRAPH IV XT, propiedad de Neurocentro.....	35
Figura 11. Electrodos utilizados para la toma de muestras.	36
Figura 12. Ubicación de electrodos para las pruebas.....	37
Figura 13. Toma de muestras de pacientes durante una sesión.	39
Figura 14. Diagrama de bloques de la aplicación.....	41
Figura 15. Señal de entrada del sistema y sus coeficientes wavelet.	42
Figura 16. Entrenamiento de la red neuronal en matlab.	43
Figura 17. Diagrama de flujo procesamiento wavelet	44
Figura 18. Wavelet madre Sym 3	45
Figura 19. Wavelet madre Sym 6.	45
Figura 20. Wavelet madre daubichies 4	45
Figura 21 Diagrama de flujo de la red LVQ en matlab.....	46
Figura 22. Diagrama de flujo manejo del Mouse	47
Figura 23. Entrada del programa.....	50
Figura 24. Ventana principal del programa.....	50
Figura 25. Módulo de verificación.....	51

ÍNDICE DE TABLAS

Tabla 1. Respuesta del canal 11 con la wavelet sym3 para estimulo visual.....	52
Tabla 2. Respuesta del canal 12 con la wavelet sym3 para estimulo visual.....	52
Tabla 3. Respuesta del canal 11 con la wavelet sym3 para movimiento.....	53
Tabla 4. Respuesta del canal 12 con la wavelet sym3 para movimiento.....	54
Tabla 5. Respuesta del canal 8 con la wavelet sym6 para estimulo visual	54
Tabla 6. Respuesta del canal 11 con la wavelet sym6 para estimulo visual.....	54
Tabla 7. Respuesta del canal 8 con la wavelet sym6 para movimiento.....	55
Tabla 8. Respuesta del canal 11 con la wavelet sym6 para movimiento.....	55
Tabla 9. Respuesta del canal 11 con la wavelet db4 para estimulo visual.....	56
Tabla 10. Respuesta del canal 12 con la wavelet db4 para estímulo visual	56
Tabla 11. Respuesta del canal 7 con la wavelet db4 para movimiento	57
Tabla 12. Respuesta del canal 11 con la wavelet db4 para movimiento	57
Tabla 13. Respuesta del canal 11 con una RNA con 358 neuronas en la capa oculta ante estimulo visual.....	58
Tabla 14. Respuesta del canal 11 con una RNA con 158 neuronas en la capa oculta ante estimulo visual.....	58
Tabla 15. Porcentaje de respuesta del canal 11 (o1) con una red neuronal con 258 neuronas en la capa oculta.....	59
Tabla 16. Porcentaje de respuesta del canal 12 (o2) con una red neuronal con 258 neuronas en la capa oculta.....	60
Tabla 17. Comparación de técnicas para BCI.....	60

ÍNDICE DE ANEXOS

ANEXO 1. FORMATOS PRESENTADOS A LOS PACIENTES, PARA IMAGINAR LOS MOVIMIENTOS.....	74
ANEXO 2. CÓDIGO CORRESPONDIENTE AL PROCESAMIENTO WAVELET EN MATLAB.....	74
ANEXO 3. CÓDIGO RED NEURONAL LVQ EN MATLAB	75
ANEXO 4. MANEJO DEL MOUSE EN JAVA	75
ANEXO 5. RESULTADOS DE LOS CANALES 1 AL 12 PARA LA WAVELET SYM 3 CON UNA RNA DE 258 NEURONAS EN LA CAPA OCULTA Y 200 CICLOS DE APRENDIZAJE PARA ESTIMULO CON IMÁGENES.	76
ANEXO 6. RESULTADOS DE LOS CANALES 1 AL 12 PARA LA WAVELET SYM 3 CON UNA RNA DE 258 NEURONAS EN LA CAPA OCULTA Y 200 CICLOS DE APRENDIZAJE PARA ESTIMULO CON MOVIMIENTOS.....	78
ANEXO 7. RESULTADOS DE LOS CANALES 1 AL 12 PARA LA WAVELET SYM 6 CON UNA RNA DE 258 NEURONAS EN LA CAPA OCULTA Y 200 CICLOS DE APRENDIZAJE PARA ESTIMULO CON IMÁGENES.	81
ANEXO 8. RESULTADOS DE LOS CANALES 1 AL 12 PARA LA WAVELET SYM 6 CON UNA RNA DE 258 NEURONAS EN LA CAPA OCULTA Y 200 CICLOS DE APRENDIZAJE PARA ESTIMULO CON MOVIMIENTOS.....	83
ANEXO 9. RESULTADOS DE LOS CANALES 1 AL 12 PARA LA WAVELET DB4 CON UNA RNA DE 258 NEURONAS EN LA CAPA OCULTA Y 200 CICLOS DE APRENDIZAJE PARA ESTIMULO CON IMÁGENES.	86
ANEXO 10. RESULTADOS DE LOS CANALES 1 AL 12 PARA LA WAVELET DB4 CON UNA RNA DE 258 NEURONAS EN LA CAPA OCULTA Y 200 CICLOS DE APRENDIZAJE PARA ESTIMULO CON MOVIMIENTOS.....	88
ANEXO 11. CARACTERÍSTICAS GENERALES DE LA HERRAMIENTA.....	90

1. INTRODUCCIÓN

Uno de los planteamientos que se presentan a nivel tecnológico consiste en establecer una interfaz entre el ser humano y la máquina de una manera no invasiva, las investigaciones determinan que es muy difícil tomar este tipo de señal. Establecer a que señal corresponde y que información posee, puede proporcionar una herramienta útil para crear una interfaz cerebro computadora.

El objetivo general de este trabajo es clasificar las señales neurológicas obtenidas a través de un equipo de electroencefalografía, para determinar la información correspondiente con una dirección, que indique intención de realizar un movimiento real o imaginado, para esto se han utilizando herramientas como las transformaciones matemáticas.

Para lograr este objetivo es necesario llevar a cabo los siguientes pasos:

- Determinar filtros digitales para la clasificación en frecuencia de las señales EEG.
- Ampliar las señales utilizando técnicas de multirresolución o similares, que permitan mejorar las características de la señal.
- Determinar algoritmos de clasificación para agrupamiento de las señales.

Se parte de los antecedentes sobre este tipo de trabajos y el modo como se está abordando las clasificaciones de estas señales. Después de conocer estos antecedentes, se continúa conociendo las señales eléctricas que el cerebro emite, las cuales son producidas en regiones específicas, según la tarea a desarrollar. Se explica como se obtiene esta información a través de un sistema de medida para electroencefalografía, que debido a su complejidad, se hace necesario hacer una descomposición de componentes por medio de transformadas matemáticas tales como la wavelet. A este tipo de información se aplica un sistema de

reconocimiento de señales con técnicas de clasificación estadísticas y no estadísticas.

Para esta investigación se implementó una interfaz de control mediante señales a partir del cerebro. A través de etapas de capturas de información utilizando una gran cantidad de electrodos y aplicando protocolos médicos para la adquisición de datos, con esto se creó una base de datos propietaria que se utilizó en el desarrollo de esta aplicación.

La interfaz de aplicación, fue desarrollada con módulos interconectados entre sí, que adquieren la información proveniente de una base de datos; luego la descomponen utilizando transformadas matemáticas, para programar luego un clasificador de datos y verificar finalmente si la información es clasificada adecuadamente.

Con las pruebas realizadas sobre esta aplicación se obtuvieron resultados muy relevantes en comparación con los antecedentes. Como por ejemplo que las señales más predominantes para el procesamiento, corresponden a los canales adheridos a la región del cerebro encargado del procesamiento visual, es decir a la región occipital del cerebro y no a la que controla el movimiento (la corteza promotora y motora), para el preprocesamiento de la información después de utilizar varias funciones wavelet de referencia, se logró encontrar una familia wavelet (sym3), que logra filtrar de una forma adecuada las señales. Además se encontró que estadísticamente, las señales que presentaron menor error fueron las correspondientes a una orden en especial, en este caso la orden centro. Para la clasificación de los datos se encontró la configuración de la herramienta que mejor encontraba características predominantes en los datos de entrada. También se debe tener en cuenta que este es un sistema que clasifica cinco órdenes, mientras que en los trabajos previos, normalmente se enfocan en estados mentales o menor numero de órdenes. Además la herramienta

desarrollada, permite una configuración que la hace particularmente útil en el desarrollo de aplicaciones futuras sobre esta área de investigación.

2. MARCO TEÓRICO

2.1 INTRODUCCIÓN

En este capítulo se inicia conociendo las aplicaciones y trabajos que se están desarrollando a nivel general con avances en el área de la clasificación de señales y la aplicación con equipos computacionales. También se describirán las señales eléctricas del cerebro que contiene este tipo de información y que son denominadas Ondas Cerebrales, las cuales se clasifican según su voltaje y frecuencia. Estas ondas son conocidas como ondas Alfa, Beta, Delta, Theta, Mu, Ram alta y ondas Gama. Estas señales se generan cuando se realizan actividades mentales complejas, las cuales son monitoreadas a través de un equipo electrónico denominado Electroencefalógrafo, estas señales se adquieren por medio de sensores denominados electrodos que se encuentran ubicados sobre la superficie del cráneo de acuerdo a un sistema internacional de ubicación denominada Sistema 10–20 que esta asociado con las diferentes regiones funcionales del cerebro.

Como las aplicaciones de interfaz cerebro computador requiere una clasificación de patrones que determinen a qué tipo de señal corresponde una información, se requiere una serie de herramientas matemáticas, ya que las señales son muy variantes en el tiempo y en la frecuencia. Para analizar estas, se utilizan transformadas matemáticas como son las transformadas de ventana de Fourier y las transformadas Wavelet estas últimas son muy útiles en señales que tienen que ser eficientemente codificadas, comprimidas y limpiadas. Con la transformada wavelet se logra discriminar las señales que tengan frecuencias bajas y frecuencias altas, y a su vez determinar el grado de detalle de la señal y de aproximación de la misma.

Para hacer una clasificación adecuada de cualquier señal es necesario utilizar tipos de funciones que permitan tener una estimación de probabilidades ante

nuevas evidencias de señales, esto se hace a través de redes Bayesianas que son clasificadores estadísticos; también se pueden utilizar redes neuronales artificiales que son algoritmos de clasificación no estadísticos y proporcionan una mejor clasificación de información después de que se ha entrenado, en la actualidad se utiliza principalmente la red neuronal LVQ(Learning Vector Quantization)

2.2 ANTECEDENTES

Los antecedentes de uso de las ondas cerebrales para control de dispositivos empiezan en los primeros años de la década de 1990, cuando el psicólogo Niels Bierbaumer¹, de la Universidad de Tübingen en Alemania, encontró que las personas pueden controlar ciertas ondas cerebrales. Para ello, desarrolló junto con su equipo de trabajo un deletreador, que a través de un entrenamiento de ondas lentas positivas y negativas, permitía seleccionar entre 2 bancos de letras para escribir mensajes. Trabajando con pacientes de Esclerosis lateral amiotrófica, se les entrenó durante cerca de 2 meses con una intensidad de 1 hora diaria, y lograron hacer que estas personas aprendieran a escribir mensajes a una rata aproximada de 2 caracteres por minuto.

El Instituto Técnico de Mediciones Eléctricas de la Universidad de Braunschweig² en Alemania en asocio con la Clínica Universitaria Charité de Berlín y el Instituto Fraunhofer de Arquitectura de Cálculo y Tecnologías de Software de la capital alemana, en un proyecto encabezado por Meinhard Schilling, desarrolló un proyecto que funciona concentrándose fijamente en un cuadro de ajedrez que indica la dirección de movimiento para un carro. El principio de funcionamiento es el encefalograma clásico y la clasificación de señales.

1. <http://www.mp.uni-tuebingen.de/mp/index.php?id=137>

2. <http://www.tu-braunschweig.de/index.html>

Bas J. de Kruif, Rebecca Schaefer and Peter Desain desarrollaron un trabajo sobre un enfoque para clasificar entre los tonos acentuados y no acentuados dentro de un simple ritmo imaginado. La clasificación se basa en el espectro y la fase de las señales. La clasificación se realizó entre los tonos acentuados y no acentuados en un conocido ritmo musical¹.

El departamento de Psicología, Universidad de Drexel, Filadelfia, Pennsylvania, y en colaboración con Departamento de Ingeniería Eléctrica y Computación de la universidad Nueva Jersey EE.UU. Genevieve Jacques PhD. en colaboración con otros, desarrollaron un algoritmo para el análisis wavelet multirresolución, que se aplica a los potenciales relacionados con la EEG y así poder lograr desarrollar un procedimiento rentable y automatizado para el diagnóstico precoz de la enfermedad de Alzheimer².

El Departamento de Electrónica y Ingeniería Biomédica, en la Universidad de Hanyang, en Seúl, con los doctores Yong Hee Lee, Sun I. Kim, Doo Soo Lee, desarrollaron varias técnicas de procesamiento de señales, con las cuales se pretende obtener una mejora de las señales producidas por estímulos (Potenciales evocados), en la cual presentan el método sobre la base de análisis wavelet para obtener una mejora del mismo en la señal EEG³.

1. Kruif, J. de y otros. Classification of Imagined Beats for use in a Brain Computer Interface, Conference of the IEEE EMBS Cité Internationale, Lyon, France August 23-26 2007.

2. POLIKAR, Robi y otros. Multiresolution wavelet analysis and ensemble of classifiers for early diagnosis of alzheimer disease. IEEE V - 389 ICASSP 2005.

3. Lee' Yong Hee y otros. Estimation of Evoked Potentials Based on the Wavelet Analysis. Proceedings - 19th International Conference - IEEE/EMBS Oct. 30 - Nov. 2, 1997.

Kenji Nakayama₁ y su equipo de trabajo, lograron clasificar tareas mentales tales como multiplicación, composición, contar, rotar objetos, entre otros. Utilizaron 6 señales de entrada a las cuales aplicaron la transformada rápida de Fourier (FFT), obteniendo resultados entre el 64% y el 74%.

Xiaomei Pei₂ y su equipo, utilizo 3 canales utilizando wavelets de morlet, para la clasificación de órdenes derecha, izquierda, determinando que solo algunos componentes de la frecuencia contienen información relevante con una orden dada.

Tao Wang₃ y su equipo, realizaron estudios en el dominio de la frecuencia de las señales EEG provenientes de los canales C3 y C4 con los que pudieron encontrar que las ondas mu y las beta contienen información útil, en la imaginación de movimientos.

L. Trejo₄ y su equipo desarrollaron una interfaz para el control del cursor usando señales EEG en conjunto con electrooculografía, obteniendo resultados entre el 58% y el 88%.

1. NAKAYAMA, Kenji. A Brain Computer Interface Based on FFT and Multilayer Neural Network - Feature Extraction and Generalization. Proceedings of 2007 International Symposium on Intelligent Signal Processing and Communication Systems Nov.28-Dec.1, 2007.
2. PEI, Xiaomei. Classification of left and right hand motor imagery tasks based on EEG frequency component selection. Proceedings of 2007 International Symposium on Intelligent Signal Processing and Communication Systems Nov.28-Dec.1, 2007.
3. WANG, Tao. Classification of Motor Imagery EEG Patterns and Their Topographic Representation. Proceedings of the 26th Annual International Conference of the IEEE EMBS San Francisco, CA, USA September 1-5, 2004.
4. TREJO, L. J.; ROSIPAL, R. and MATTHEWS, B. "Braincomputer interfaces for 1-D and 2-D cursor control: designs using volitional control of the EEG spectrum or steady-state visual evoked potentials". IEEE Transactions on Neural Systems and Rehabilitation Engineering, vol. 14, No. 2, June 2006.

J. Deng₁ utilizó la densidad espectral de potencia para procesar 3 canales con redes neuronales artificiales y clasificar señales correspondientes a movimiento a la izquierda y a la derecha, obteniendo resultados del 72.2 % en las pruebas.

Robert Rasmussen₂ de la universidad de Baltimore, realizó pruebas de entrenamiento, utilizando los canales C3, C4 y Cz, donde se encontró que ante dos tareas a clasificar, se obtenía un porcentaje de clasificación aproximado del 72%, mientras que si el número de tareas a clasificar era 4, el porcentaje disminuía 45%

A nivel nacional, en la Universidad del Valle se presentó en 1999 un trabajo de grado titulado "Procesamiento de señales provenientes del cerebro" por parte de Olga Lucia Gamboa Arana, que muestra el estudio de las técnicas matemáticas para este análisis. Actualmente no hay resultados disponibles de otros trabajos que se estén realizando en este campo.

2.3 SEÑALES ELECTROENCEFALOGRÁFICAS (EEG)


La electroencefalografía₃ es el procedimiento que consiste en medir las señales del cerebro con el fin de estudiar el sistema nervioso; esto se hace uniando los electrodos en el cuero cabelludo o en la corteza cerebral (ésta es esencial en funciones importantes del cerebro como la memoria, la atención, el conocimiento perceptivo, el “pensamiento”, la lengua y los sentidos), estos electrodos transmiten las señales u ondas cerebrales proporcionadas por un gran conjunto de neuronas en los individuos a los que se les practica.

1. DENG, J. HE, B. Classification of Imaginary Tasks from Three Channels of EEG by Using an Artificial Neural Network. Proceedings of the 25th Annual International Conference of the IEEE EMBS.2003.
2. RASMUSSEN, Robert G. y otros. Accuracy of a Brain-Computer Interface in Subjects with Minimal Training. Department of Biomedical Engineering, Johns Hopkins University Baltimore, MD 21205IEEE. 2006.
3. RANGAYAN, RANGARAJ M. Biomedical signal análisis, IEEE, 2002

El EEG se utiliza para probar la función del cerebro, registra las diferencias del voltaje entre las partes del cerebro, pero no mide corrientes eléctricas. Se utiliza popularmente en la experimentación pues se aplica principalmente con medidas no invasivas. Por otra parte, el paciente no necesita hablar, trasladarse, o aún demostrar ninguna emoción para registrar los datos; el aparato puede incluso detectar señales eléctricas resultantes de respuestas secretas a los estímulos.

Se debe tener en cuenta para la ubicación de electrodos, la división funcional del cerebro (figura 1), en donde se pueden observar, las diferentes regiones del cerebro y la relación funcional de los mismos. Allí se puede notar que existe una región correspondiente a la iniciación de movimientos voluntarios (área premotora), otra utilizada en el control de movimientos complejos (corteza motora primaria) y otra relacionada con la corteza visual. Estas regiones, tienen la importancia de ser los puntos de origen de las señales nerviosas que se convierten en funciones específicas como el movimiento o la visualización₁.

Figura 1. División funcional del cerebro




Fuente: <http://aprendemente.blogspot.com/>

1. GUYTON ARTHUR C. Tratado de fisiología medica, 11 edición, Elsevier España, 2006

Los electrodos en el cuero cabelludo se utilizan para obtener la grabación. Antes de esto, el área es preparada, generalmente por abrasión ligera y el uso de un gel conductor para prevenir cualquier problema.

Figura 2. Ubicación de electrodos en el sistema 10-20



1. WINDHORST, Uwe. Modern Techniques in Neuroscience Research. Springer_Verlag. 1999

Cada punto de la figura 2 indica un posible electrodo, cada localización tiene una letra para identificar el Lóbulo y un número u otra letra para identificar la localización del hemisferio. Las Letras F, T, C, P y O identifican los lóbulos Frontal, Temporal, Central, Parietal y Occipital.

Los números (2, 4, 6, y 8) se refieren al Hemisferio derecho y los demás números (1, 3, 5, y 7) se refieren al hemisferio izquierdo. La Z esta referida al electrodo colocado en la línea media. Además nótese que los números más pequeños corresponden a los más cercanos a la línea media. El punto "Nasion" se encuentra entre la frente y la nariz, el punto "Inion" es el tope posterior del cráneo.

Cada par de electrodos está conectado a un amplificador diferencial (un electrodo por entrada). La amplificación del voltaje entre los electrodos se pone en (típicamente) 1.000 - 100.000 veces, o 60 – 100 dB del aumento del voltaje. Cada señal del voltaje proveniente del amplificador diferencial se hace pasar a través de filtros, que dejan pasar señales entre 0.5 Hertz y 35-70 Hertz.

Hay tres maneras de arreglar las relaciones del electrodo-amplificador:

- **Derivación común de la referencia.** Esta técnica utiliza un electrodo como referencia en alguna parte a lo largo de la línea media del cuero cabelludo. Cada amplificador es conectado con este mismo electrodo por un terminal (cada amplificador tiene dos). Todos los otros electrodos se colocan con respecto al punto de referencia. El electrodo de la referencia une ambos electrodos del lóbulo de la oreja.
- **Derivación media de la referencia.** La señal toma un promedio de todos los amplificadores y se utiliza como referencia común para cada uno.
- **Derivación bipolar.** Un número igual de electrodos está conectado en serie con los amplificadores correspondientes (un amplificador para 2

electrodos). En este arreglo, el amplificador 1 mide la diferencia entre los electrodos A y B; el amplificador 2, por otra parte, mide la diferencia entre B y la C.

La sensibilidad de los electrodos del cuero cabelludo no es suficiente para capturar la unidad eléctrica individual de una parte en el cerebro o los potenciales de acción. Por otra parte, no puede determinarse ciento por ciento si la actividad eléctrica es dada por neurotransmisores inhibitorios, excitatorios o modulatorios.

El EEG detecta solamente la actividad de grupos grandes de neuronas, que en proporción, producen un mayor voltaje que la emitida por una neurona individual.

El EEG tiene varias ventajas: Es en tiempo real, comparado a otros métodos que exploran la actividad del cerebro la diferencia del tiempo de adquisición entre datos es menor a los milisegundos, mientras que otros métodos tienen diferencias que pueden medirse desde segundos a los minutos.


Las ondas cerebrales pueden clasificarse según la frecuencia y voltaje¹ en: Delta, Theta, Alfa, Mu, Beta, Ram alta y ondas gamma. Las características de estas son:

2.3.1 Delta

Señal de 10 a 50 micro voltios y una frecuencia de 0,2 a 3,5 Hz. (Ver Figura 3). Corresponde a un estado hipnótico, trabajo del hemisferio cerebral derecho en plena actividad, sueño profundo y meditación.

1. BALLESTEROS, Dora y otro. Software de Análisis de Energía en señales Electroencefalográficas Básicas en la Transformada Wavelet Discreta. Fundación Universitaria Gabriela Bertrán, 2005


Figura 3. Onda Delta



2.3.2 Theta

Señal de 50 a 100 micro voltios de 3,5 a 7,5 Hz. Se puede ver en la figura 4 y corresponde a un estado de vigilia, equilibrio entre los hemisferios izquierdo y derecho.


Figura 4. Onda Theta



2.3.3 Alfa

Señal de 100 a 150 microvoltios entre 7,5 a 13 Hz. Se puede ver en la figura 5 y corresponde a un estado de relajación, tranquilidad, creatividad inicio de actividad plena del hemisferio izquierdo y desconexión del hemisferio derecho.


Figura 5. Onda Alfa



2.3.4 Mu

Las ondas Mu (ver Figura 6), son ondas espontáneas que se encuentran en la banda de frecuencia entre 8 Hz y 13 Hz, igual que las ondas Alfa. Ellas se registran principalmente en la zona Sensorio-motora (ver figura 1) y se registran en la posición C del sistema de colocación de electrodos (ver figura 2), manifestando una atenuación durante el movimiento o intento de movimiento de extremidades.


Figura 6. Onda Mu



2.3.5 Beta

Señal de 150 a 200 micro voltios con frecuencias de 13 a 28 Hz (ver figura 7) Corresponde a estado de alerta máxima, vigilante, miedo, es la situación normal cuando estamos despiertos, conduciendo, o trabajando en donde estamos en estado de alerta, ansiedad.

Figura 7. Onda Beta



2.3.6 Ram-alta

Señal superior a los 200 micro voltios y frecuencias mayores de 28 Hz. Corresponde a estados de stress y confusión.

2.3.7 Ondas Gama

Las ondas Gama se encuentran desde los 30 Hz hacia arriba. Se piensa que éstas reflejan el mecanismo subyacente de la conciencia. Se ha observado que las ondas Gama están asociadas a procesos de comunicación, feedback y sincronización entre las distintas zonas neuronales - módulos cerebrales - durante la realización de actividades mentales complejas.

2.4 SISTEMAS CONTROLADOS POR EEG

La Interfaz Cerebro – Computador, actúa mediante la detección de actividad mental por medio de señales electrofisiológicas, tales como los impulsos de un electroencefalograma (EEG) o los de un electrocorticograma ("ECoG"). Estos impulsos son traducidos a señales de control. De esta forma, las ondas cerebrales pueden ser usadas para ingresar datos o mover el cursor en un monitor de un Computador.

El controlar dispositivos con la mente ha sido por mucho tiempo un tema recurrente en la ciencia ficción y mientras éste continúa alimentando a la imaginación, es posible permitir que pacientes completamente paralizados puedan comunicarse e interactuar con el medio ambiente.

La señal, captada en el cuero cabelludo, presenta una variación de amplitud en torno a las decenas de microvoltios y en el rango de frecuencia comprendido aproximadamente entre 0.1 y 60Hz. Si se consiguiera aprender rápidamente a controlar dichas características, la señal EEG podría presentar una nueva función

cerebral; podría convertirse en una nueva señal de salida que permitiera comunicar los deseos de una persona a un componente externo.

Las ondas Mu, que corresponde a una oscilación de la señal EEG comprendida entre los 8 y 13Hz, es captado en la zona sensomotora situada en la región central del cuero cabelludo. Dicho ritmo, presente en la mayoría de los adultos, tiene la particularidad de presentar una atenuación en su amplitud cuando se lleva a cabo algún tipo de movimiento, o lo que es más importante cuando se tiene la intención de realizar algún movimiento, o sencillamente imaginando movimientos de las extremidades.

Extrayendo características de la electroencefalografía humana se puede llevar a cabo interfaces cerebro-computadora. Se hace necesario llevar a cabo un entrenamiento de los datos para cada individuo. Al ser cada individuo diferente, se deberá analizar las señales adecuadamente y ajustar los parámetros convenientemente para lograr una buena clasificación de la señal. Inicialmente en la fase de entrenamiento, es importante observar en tiempo real la evolución de las ondas Mu para cada individuo y para las diferentes actividades mentales.

2.5 TRANSFORMADAS MATEMÁTICAS

En el procesamiento de señales se pueden encontrar diferentes tipos de señales estacionarias y no estacionarias. Las primeras son localizadas en el tiempo, ya que su frecuencia no varía. Este tipo de ondas son estudiadas por medio del análisis de Fourier, que permite su descomposición en términos de funciones sinusoidales, es decir, transforma la señal de la base de tiempo a la base de frecuencia y de igual manera permite el paso del dominio de la frecuencia al dominio del tiempo; sin embargo en este último se pierde información necesaria, que por ser de carácter estacionario, no resulta relevante.

2.5.1 Transformadas de ventanas de Fourier

En el caso de las señales con comportamiento no-estacionario, es decir, aquellas cuya frecuencia varía en el tiempo, al tener la señal producto de la transformada de Fourier resulta imposible realizar el paso al dominio del tiempo porque no permite determinar en que momento se presenta un cambio en la frecuencia.

Surge entonces la necesidad de contar con una representación localizada en el tiempo y la frecuencia, como consecuencia de la desventaja presentada por el análisis de Fourier. De esta manera Gabor implementa el uso de la STFT (Short Time Fourier Transform), que consiste en analizar una pequeña sección de la señal a través de una ventana de longitud fija, llevando la información contenida en este pequeño intervalo del dominio del tiempo a la escala bidimensional de tiempo y frecuencia, donde se puede conocer cuándo y a qué frecuencia ocurre un suceso.

2.5.2 Wavelet

En el entorno actual existen señales por todas partes que necesitan ser analizadas: Los temblores sísmicos, el habla humana, las vibraciones de un motor, las imágenes en medicina, los datos financieros, la música y muchos otros tipos de señales que tienen que ser eficientemente codificadas, comprimidas, limpiadas, reconstruidas, descritas, simplificadas, modeladas, distinguidas, o localizadas. El análisis Wavelet¹ es un conjunto de técnicas matemáticas para conseguir estos objetivos.

Desde un punto de vista histórico, el análisis Wavelet₁ es un método nuevo, ya que sus Apoyos matemáticos se remontan desde el trabajo de Joseph Fourier en el siglo XIX. Fourier puso los fundamentos con sus teorías de análisis de

1. Stephane Mallat. A WAVELET TOUR OF SIGNAL PROCESSING

frecuencias, conceptos matemáticos de importancia e influencia en el análisis de señales. La primera mención registrada del término 'wavelet' fue en 1909, en la tesis de Alfred Haar. El concepto de wavelets¹ en su forma teórica actual fue primeramente propuesto por Jean Morlet y por el equipo del Marseille Theoretical Physics Center (Francia). Los métodos de análisis wavelet han sido desarrollados principalmente por Y. Meyer y colaboradores, y los principales algoritmos se remontan al trabajo de Stephane Mallat en 1988.

Este trabajo se centra en las wavelets Daubechies y Symlet₁, que son las que se utilizan habitualmente en Estadística. Estas funciones se caracterizan porque son ortogonales y de soporte compacto, poseen diferente grado de suavidad y tienen el máximo número de momentos nulos en el dominio del tiempo, dependiendo de su anchura.

La construcción de wavelets de soporte compacto se debe a Daubechies. Esta autora desarrollo un algoritmo para su construcción y las presento proporcionando los coeficientes filtro h_l , los cuales son ortogonales y verifican la propiedad de los momentos nulos. Las primeras wavelets de soporte compacto con un determinado grado de suavidad, creadas por Daubechies, se conocen como Daubechies.

Habitualmente se denotan por dbN , con N el orden que es un número entero estrictamente positivo. Las $db1$ son un caso especial de Daubechies que reciben el nombre de Haar. Estas wavelets son las únicas simétricas y de soporte compacto. Desde un punto de vista didáctico, las Haar son muy interesantes; pero desde un punto de vista práctico no son útiles, ya que presentan discontinuidades. Daubechies demostró que, excepto el sistema de wavelets Haar, ningún sistema \hat{A} , \tilde{A} puede ser simétrico y de soporte compacto al mismo tiempo. Sin embargo, desde un punto de vista práctico (por ejemplo en el procesamiento de imágenes) es posible aproximarse a la simetría utilizando otro tipo de wavelets de soporte

1. Rezual Begg, COMPUTATIONAL INTELLIGENCE FOR MOVEMENT SCIENCES

compacto, que reciben el nombre de Symmlets o menos asimétricas. La notación utilizada para la Symmlet de orden N es sym N, con N el orden que es un entero estrictamente positivo.

2.5.2.1 El análisis Wavelet

El análisis Wavelet representa el siguiente paso lógico: una técnica donde se utilice ventanas con tamaño variable. El análisis Wavelet permite utilizar intervalos temporales largos donde queramos más información precisa de baja frecuencia, y regiones más cortas donde queramos una información de alta frecuencia. Con esto se muestra las diferentes características que distinguen a cada una de las principales técnicas de análisis de señales: el dominio temporal (Shannon), el dominio de frecuencias (Fourier), el dominio tiempo-frecuencia (análisis Wavelet).

Una ventaja importante del análisis Wavelet es la habilidad para realizar análisis locales. Consideremos, por ejemplo, una señal sinusoidal con una pequeña discontinuidad, tan pequeña que apenas es visible. Una representación de los coeficientes de Fourier de esta señal no mostraría nada particularmente interesante: un espectro plano con dos picos representando una única frecuencia. No obstante, una representación de los coeficientes wavelet mostraría claramente la situación de la discontinuidad en el tiempo.

Por tanto, el análisis Wavelet es capaz de revelar aspectos de los datos que otras técnicas de análisis de señales pierden, aspectos tales como tendencias, puntos de ruptura, discontinuidades, etc.

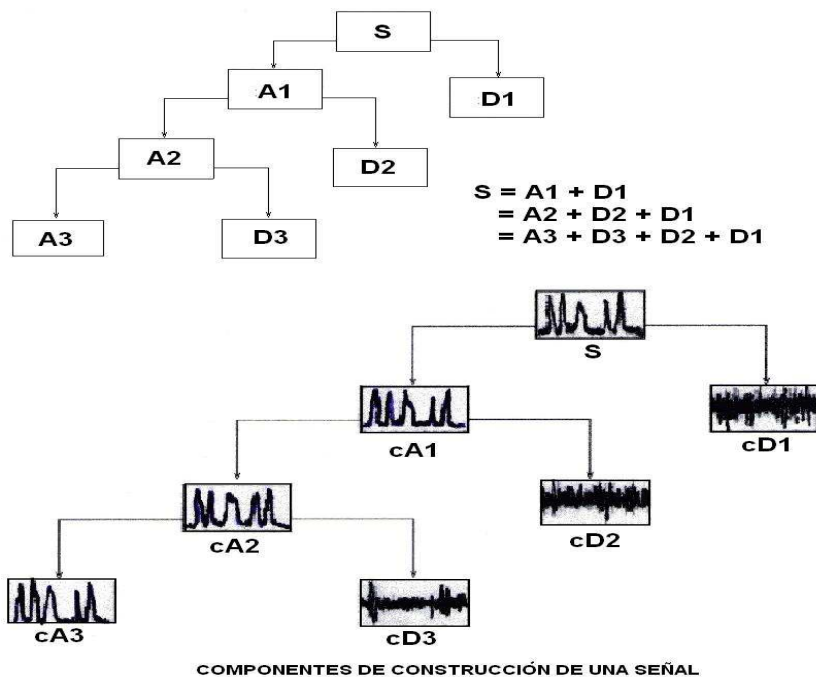
2.5.2.2 Qué es el análisis Wavelet?

El análisis Wavelet₁ consiste en la descomposición de una señal original (s) en

1 Mallat. OP. CIT

una aproximación (A) y un detalle (D), ver la figura 8. La aproximación es entonces descompuesta en un segundo nivel de aproximación y detalle, y el proceso es repetido sucesivamente.

Figura 8. *Modo de descomposición de la señal (S), en que opera el análisis Wavelet. De cada descomposición se obtiene una aproximación (A) y un Detalle (D)*



Para un nivel n de descomposición, existen $n+1$ maneras posibles para descomponer o codificar la señal.

Un wavelet es una forma de onda, de duración limitada, que tiene un valor medio de cero (0). Comparemos, como ejemplo, los wavelets con las ondas de la función $\sin(x)$ (éstos últimos son la base del análisis de Fourier). Las sinusoides no tienen una duración limitada, es decir, se extienden infinitamente. De esta forma, mientras que las sinusoides son suavizadas y predecibles, los wavelets tienden a ser irregulares y asimétricos.

Las señales con cambios bruscos pueden ser mejor analizadas con un wavelet irregular más que con un senoide suavizado. De esta forma, las características locales pueden ser mejor descritas con wavelets, ya que tienen una extensión local.

2.6 SISTEMAS DE RECONOCIMIENTO DE PATRONES

El Reconocimiento de Patrones es una tarea inteligente que consiste en tratar de identificar patrones de referencia conocidos previamente, dentro de un conjunto de datos de entrada, utilizando las características más relevantes de la misma. El tipo de patrones a clasificar, puede tener cualquier forma pasando por imágenes, señales con formas de onda periódicas y partes de una onda no periódica. Estos patrones normalmente se pueden definir en un espacio multidimensional.

El procedimiento a seguir en un sistema de reconocimiento de patrones es: Primero obtener los patrones a través de un **sistema sensorial**; luego se hace una **segmentación y agrupamiento** que trata de delimitar la señal a procesar, posteriormente se trata de **extraer las características** que proveen similitud entre los patrones, la **clasificación** que es el siguiente paso, consiste en comparar el vector de características obtenido, con los patrones aprendidos y finalmente está el **procesamiento posterior**, que consiste en la toma de decisiones sobre el proceso a seguir con los datos obtenidos.

Para la clasificación se escoge como procedimiento:

La *teoría de la decisión (clasificación estadística)*. Se basa en las características estadísticas, asumiendo que los produzcan sistemas probabilísticos.

El procedimiento estructural (sintáctica). Se basa en las relaciones estructurales de las características.

El conjunto de patrones de aprendizaje, si es conocido previamente para el proceso de entrenamiento se dice que proporciona un aprendizaje *supervisado*; mientras que si se hace sin conocer los patrones con anticipación sino que produce un cálculo estadístico para el aprendizaje, se dice que es *no supervisado*.

2.6.1 Sistemas de reconocimiento de patrones estadísticos

Se presentan situaciones, donde un fenómeno no es posible modelarlo matemáticamente, debido a su naturaleza propia. En estas situaciones, se hace necesario, generar modelos de caja negra, es decir modelos que calculen la probabilidad de una salida, teniendo como referencia, algunas variables de entrada.

2.6.1.1 Redes bayesianas¹

Es un modelo de aprendizaje que relaciona un conjunto de variables aleatorias a través de un grafo dirigido que muestra la influencia causal. Utiliza el teorema de Bayes para determinar la influencia de cierta evidencia, permitiendo tener una estimación de probabilidad ante nuevas evidencias.

Tiene un aprendizaje paramétrico, es decir toma el nuevo conocimiento, con referencia a los casos presentados previamente. El aprendizaje puede tomar solo una fracción de datos para el aprendizaje por expansión - Maximización EM o todos los datos para el aprendizaje por selección de la máxima probabilidad ML.

En su aprendizaje estructural tiene algoritmos basados en pruebas de independencia y también por puntuación y búsqueda, teniendo en cuenta para la puntuación la penalización para la obtención del grafo mas optimo.

1. FERNÁNDEZ, Enrique. Análisis de clasificadores bayesianos laboratorio de sistemas inteligentes, Universidad de Buenos aires. 2005.

2.6.2 Redes neuronales artificiales (RNA)

Las redes neuronales artificiales son modelos computacionales que emulan el cerebro, tomando como elementos de procesamiento las neuronas artificiales, que son similares a las neuronas biológicas, a nivel funcional, es decir, toman una cantidad de conexiones que pueden provenir de otras neuronas, o de elementos sensores (entradas) y después de realizar una ponderación de cada entrada con el peso asociada a la misma, se obtiene una salida al aplicar esta ponderación, a una función de activación.

La respuesta a diferentes entradas, depende de la topología de la red, encontrándose redes de conexión hacia adelante, redes de con conexión lateral y mapas auto organizativos.

Lo que permite a la red saber nuevos datos, es el algoritmo de aprendizaje, que es la forma en que los datos son utilizados para calcular el valor de importancia de cada entrada a la salida correspondiente. Modificando el peso de la neurona de entrada correspondiente, dicho algoritmo puede tomar los datos para producir conocimiento y probarlo en una sola etapa, es decir tener un aprendizaje Online, pero también puede discriminar la etapa de aprendizaje de la de verificación teniendo un aprendizaje Offline.

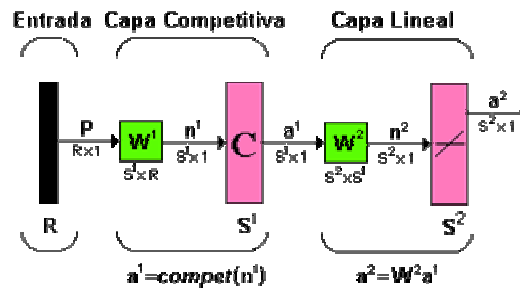
2.6.2.1 Red neuronal LVQ (Learning Vector Quantization),

Esta red es un híbrido que emplea tanto aprendizaje no supervisado, como aprendizaje supervisado para clasificación de patrones. En la red LVQ, ver figura 9, cada neurona de la primera capa es asignada a una clase, después cada clase es asignada a una neurona en la segunda capa. El número de neuronas en la primera capa, S1 debe ser mayor o al menos igual que el número de neuronas en

1. <http://ohm.utp.edu.co/neuronales/Capitulo2/Competitivas/LVQ.htm>

la segunda capa, S^2 .

Figura 9. Estructura de una red LVQ



Fuente <http://ohm.utp.edu.co/neuronales/Capitulo2/Competitivas/LVQ.htm>

Al igual que con redes competitivas, cada neurona en la primera capa de la red LVQ aprende un vector prototipo, el cual permite a la neurona clasificar una región del espacio de entrada, sin embargo en lugar de calcular la distancia entre la entrada y el vector de pesos por medio del producto punto, la red LVQ calcula la distancia directamente.

Una ventaja de hacer el cálculo de la distancia directamente, es que los vectores no necesitan ser normalizados, cuando los vectores son normalizados la respuesta de la red será la misma sin importar la técnica que se utilice.

2.7 MARCO CONCEPTUAL

Electroencefalograma (EEG): es un estudio mediante el cual se mide la actividad eléctrica en el cerebro, lo que se denomina ondas cerebrales. Un EEG mide estas ondas a través de pequeños electrodos en forma de botón que se colocan sobre el cráneo y registran la actividad espontánea del cerebro.

Transformada corta de Fourier (Stft): Es una variante de la transformada de Fourier que permite encontrar los componentes de frecuencia en rangos específicos de tiempo de una de señal de entrada.

Redes neuronales artificiales (Rna): Algoritmos que simulan el funcionamiento del cerebro y que permiten, entre otras cosas, la clasificación de datos aleatorios.

Wavelets: Funciones que permite obtener una descomposición de señales, que presenten cambios abruptos en sus componentes de tiempo-frecuencia en forma instantánea, a través del análisis de multirresolución con ventanas de longitud variable, adaptadas al cambio de frecuencia de la señal.

Redes Bayesianas: Algoritmos de clasificación estadísticos que computan la probabilidad de un evento previo

2.8 CONCLUSIONES

- Las ondas cerebrales, son señales con contenido de frecuencias entre 1 y 30 Hz aproximadamente. Según la frecuencia de salida, se puede identificar un estado o una actividad mental.
- Al ser señales de bajo voltaje, es necesario amplificarlas y filtrarlas adecuadamente, debido a su sensibilidad al ruido, producido por el medio de propagación que es el cuero cabelludo.
- Al ser señales variantes con el tiempo, no es posible procesarlas con técnicas de análisis clásicos en el tiempo o en la frecuencia, siendo necesario utilizar análisis tiempo-frecuencia.
- Para el procesamiento de la señal, es necesario utilizar herramientas que clasifiquen alto número de datos, siendo lo más óptimo la utilización de algoritmos con redes neuronales, ya que son robustas en la predicción, la

minería de datos (data mining), el reconocimiento de patrones y los sistemas de control adaptativo.

3. DESCRIPCIÓN DE LA PLATAFORMA DE EXPERIMENTACIÓN

3.1 INTRODUCCIÓN

Para desarrollar este proyecto se requiere una serie de equipos electrónicos y software computacional, que se utilizan para almacenar la información de la base de datos propietaria que posteriormente se procesa utilizando las herramientas computacionales adecuadas. En esta sección, se va conocer el equipo utilizado para dicha toma de muestras, así como la variación al sistema de referencia, teniendo en cuenta que según la mayor parte de la bibliografía consultada, se refería a la zona motora, tratándose en dicha modificación de hacer énfasis en esta región para la obtención de la información. Luego se dan las características del equipo de procesamiento y se explica el protocolo utilizado para la recolección de información.

3.2 ETAPA DE CAPTURA DE INFORMACIÓN


La captura de información, se realizó utilizando un equipo de electroencefalografía médico modelo CEEGRAPH IV XT marca BIOLOGIC de 64 canales y 512 Hz de frecuencia de muestreo (Figura 10), perteneciente a la institución médica Neurocentro y ubicado en la clínica los Rosales en la ciudad de Pereira que es un equipo que mide la actividad bioeléctrica proveniente del cerebro.

Figura 10. Equipo CEEGRAPH IV XT, propiedad de Neurocentro




Este equipo, utiliza un conjunto de electrodos de oro de 1 cm de diámetro (Figura 11), que se ubican sobre el cuero cabelludo y dependiendo de su ubicación reciben información que puede ser asociada con una zona de acción.

Figura 11. Electrodos utilizados para la toma de muestras.



El sistema de ubicación de electrodos más utilizado, es el sistema 10-20 que asocia los diferentes electrodos ubicados como se muestra en la figura 2 con una zona en la división fisiológica funcional visto en la figura 1. La ubicación que se seleccionó no fue la de este sistema sino la mostrada en la figura 12. Debido a que se pretendía medir la actividad relacionada con la corteza motora, se escogió la ubicación de un grupo 8 electrodos a lo largo de la misma, además de dos electrodos más en la región occipital que es la correspondiente a la región visual. Una vez tomadas las muestras fueron almacenadas en un archivo externo, para ser utilizadas offline en el software de procesamiento de señales.

Figura 12. Ubicación de electrodos para las pruebas.



3.3 EQUIPO DE PROCESAMIENTO

El procesamiento de la información se realizó utilizando una serie de funciones matemáticas que son implementadas en la herramienta de desarrollo Matlab Versión 2008a (Matrix Laboratory) de Mathworks, el cual es un software matemático con un entorno de desarrollo integrado, que utiliza su propio lenguaje de programación (Lenguaje M). La principal característica es que incluye funciones para el tratamiento matemático de arreglos y funciones especiales para el procesamiento de señales como las fft y las wavelets, que serían muy difíciles de implementar en otra herramienta.

La interfaz de la aplicación, fue desarrollada sobre la herramienta de RAD (Rapid application development) propietaria de Matlab llamada GUIDE, con la cual se crearon las interfaces de ventanas correspondientes a los módulos de entrenamiento y verificación del sistema.

Debido al alto gasto computacional necesario para el procesamiento de las funciones matemáticas en Matlab, se utilizó un equipo de cómputo de características avanzadas, mostradas a continuación: Procesador Intel Core 2 Duo

de 2GHz, con 4 Gb de memoria DDR2 de 667 Mhz. La aplicación se trabajo en Matlab sobre Windows Vista Home Basic 32 bits y sobre Linux Ubuntu 9.10 de 64 bits siendo mas rápido el funcionamiento sobre el sistema operativo Ubuntu.

3.4 PROTOCOLO DE TOMA DE MUESTRAS

Lo primero que se debió determinar fue cuáles serian las tareas mentales que se deseaban reconocer, es decir, qué señales serian identificadas y traducidas a comandos específicos. En este trabajo, se escogieron los movimientos típicos de un mouse (arriba, abajo, izquierda, derecha, clic).

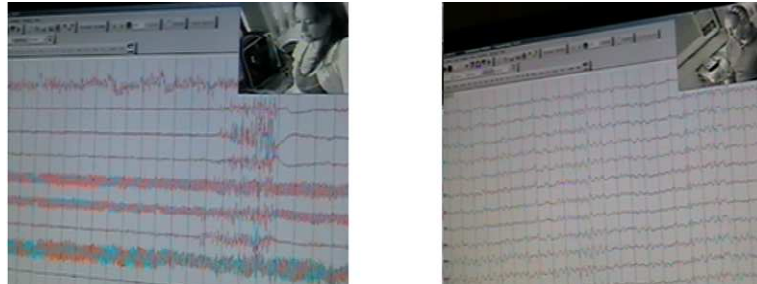
Imaginar un movimiento genera el mismo proceso mental e incluso físico, a excepción de que el movimiento queda bloqueado. La respiración y el pulso se aceleran de forma similar tanto cuando se está pensando en la acción como cuando se está realizando el ejercicio. Por último, incluso la duración de la acción real y su simulación son similares.

El procedimiento de toma de muestras a realizar es: se indica al individuo que comience a imaginar la acción motora que se la ha enseñado en tarjetas gráficas previamente (Ver Anexo 1). Los datos se graban durante los cinco primeros segundos desde la señal de inicio y estas pruebas se repiten en diferentes momentos hasta dar como resultado la grabación de un número suficiente de datos correspondiente a 20 muestras por movimiento para la experimentación.

Los pacientes utilizados en las pruebas de inicio fueron una mujer de 24 años y un hombre de 36 años (Figura 13). La respuesta se esperaba para 2 tipos de salida, la imaginación del movimiento de forma visual al ver las tarjetas y el movimiento mismo de la muñeca derecha al dar la orden correspondiente al movimiento. Con estas muestras se desarrolló la interfaz y los protocolos de clasificación de las señales y posteriormente se entrenó la interfaz con cinco individuos más para

maximizar la aplicación del proyecto a los cuales se le tomaron un número de 20 muestras y así determinar que tipo de señal entregaba una mejor respuesta.

Figura 13. Toma de muestras de pacientes durante una sesión.



3.5 CONCLUSIONES

- Los equipos electrónicos de captura de información proveniente del cerebro, al tener que interactuar con el cuero cabelludo, estando alejados de la fuente real de la señal, requieren una alta inmunidad al ruido así como de niveles altos de amplificación.
- La simulación mental de un movimiento, presenta una salida diferente a un estado de reposo, lo que puede servir para identificar estados mentales de acción.
- Las señales de movimiento, así como de intención del mismo, se pueden obtener con la ubicación de electrodos cercanos al área motora del cerebro.
- Cada individuo tiene patrones EEG distintos y por tanto el sistema debe ser entrenado para operar con cada usuario concreto. En la práctica el sistema debe aprender qué características del EEG de cada usuario corresponden a sus diferentes estados mentales.

4. DESCRIPCIÓN FUNCIONAL

4.1 INTRODUCCIÓN

Debido a que se utilizó para la creación de la base de datos propietaria, un equipo de EEG clínico, se requirió adecuar la información obtenida del mismo para poder ser usado por los módulos creados en Matlab. En este capítulo, se muestran los bloques de funcionamiento de la aplicación desarrollada para esta investigación. Se muestra los diagramas de flujo correspondientes a los diferentes bloques, las familias wavelet utilizadas en la etapa de preprocesamiento de la información y la estructura de la red neuronal LVQ utilizada para la clasificación.

4.2 FORMATO DE LOS ARCHIVOS PROVENIENTES DEL EEG

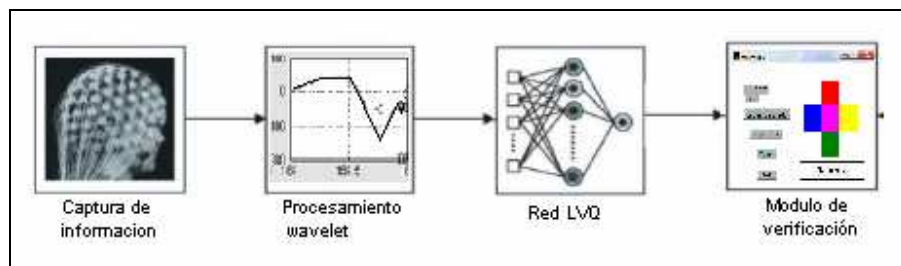
El equipo de electroencefalografía CEEGRAPH IV XT posee un formato propietario .eeg para los estudios realizados con él. Debido a que Matlab requiere leer los vectores en formato mat o txt directamente, se realizaron pruebas con diferentes toolbox para leer las señales provenientes del equipo, entre ellos se utilizó el paquete eeglab que lee formatos de diferentes equipos incluidos algunos .eeg. El problema con los diferentes toolbox fue que el formato del equipo CEEGRAPH IV XT, no era compatible con ninguno de estos, así que se debió recurrir a una herramienta de conversión propietaria de BIOLOGIC y con ella convertir los datos primero a .edf que era uno de los formatos soportados por eeglab, pero sin obtener las variables de una forma adecuada, luego utilizando la misma herramienta, se decidió convertirlo a un archivo .txt plano. Este archivo contenía la información de los canales que se abrió posteriormente con una hoja electrónica. Microsoft Excel debido el límite de filas de este programa de 65534 no se pudo utilizar, siendo necesario el cambio de software de hoja electrónica por OpenOffice que supera por mucho este valor. En esta hoja electrónica, se

separaron los canales y se salvaron como archivos de texto plano para cada uno de los canales, para ser utilizados posteriormente en Matlab.

4.3 DIAGRAMA DE BLOQUES

La aplicación está diseñada como un conjunto de módulos interconectados entre sí, los cuales son los siguientes: Un módulo de captura de información proveniente del EEG, un módulo para el procesamiento Wavelet, una red neuronal LVQ y por ultimo un módulo de verificación de movimiento. En la figura 14 se observa el diagrama de interconexión entre los módulos, y posteriormente se dará una explicación breve de cada uno de ellos. Para un mayor detalle de la aplicación completa, se puede referir al Anexo 11.

Figura 14. Diagrama de bloques de la aplicación



4.3.1 Módulo de entrenamiento

4.3.1.1 Captura de información


El primer paso en la captura de información consiste en la medición de señales de EEG sin procesar. Estas señales son muy pequeñas y son fácilmente contaminadas por ruido. En este módulo se adquiere las señales y se configura la frecuencia de muestreo que tiene un valor predeterminado de 512 muestras por segundo, pero que se puede modificar al parámetro de los datos entregados por el equipo medico; además establece la longitud de tiempo de la señal a utilizar para

el análisis; que es puede ser 1 segundo o más en tiempo real. También permite cargar dos canales de información para su análisis, y permite salvar los datos cargados, para un posterior uso.

4.3.1.2 Procesamiento Wavelet

En este módulo se selecciona el tipo de wavelet madre que se va a utilizar para el análisis, así como el orden de los coeficientes de aproximación y detalle a calcular (Figura 15). También realiza el análisis mismo y permite salvar los vectores generados para cada uno de ellos coeficientes.

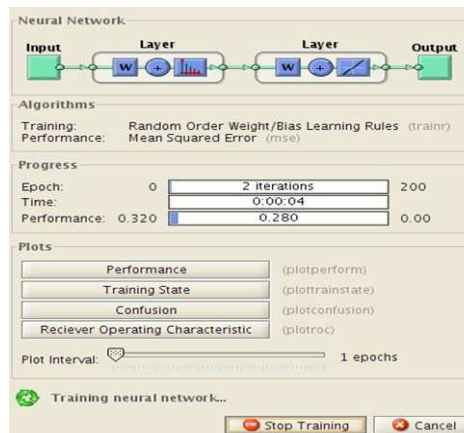
Figura 15. Señal de entrada del sistema y sus coeficientes wavelet.



4.3.1.3 Entrenamiento de la red neuronal LVQ

Este módulo se configura con un archivo que contiene la salida deseada para cada uno de los patrones de entrada que son los coeficientes wavelets que se obtuvieron previamente con los que se van a entrenar y también se selecciona el nombre inicial de cada uno de los archivos con patrones a entrenar, el número de neuronas en la capa oculta y el número de clases que se van a utilizar para clasificar las entradas. En la aplicación deben ser 5 clases para las señales arriba, abajo, izquierda, derecha y centro en ese orden. El módulo también llama al toolbox de matlab (Figura 16) para realizar el entrenamiento de la red misma. Una vez entrenada la red, existe la opción de salvar las variables del entorno en un archivo .mat, que contiene el entrenamiento de la RNA, la frecuencia de muestreo y el tipo de análisis wavelet que se realizó, así como su resolución máxima.

Figura 16. Entrenamiento de la red neuronal en matlab.



4.3.2 Módulo de verificación

Este módulo puede cargar un entrenamiento existente desde un archivo .mat, y luego cargar un vector desde un archivo .txt que corresponda a la entrada de un

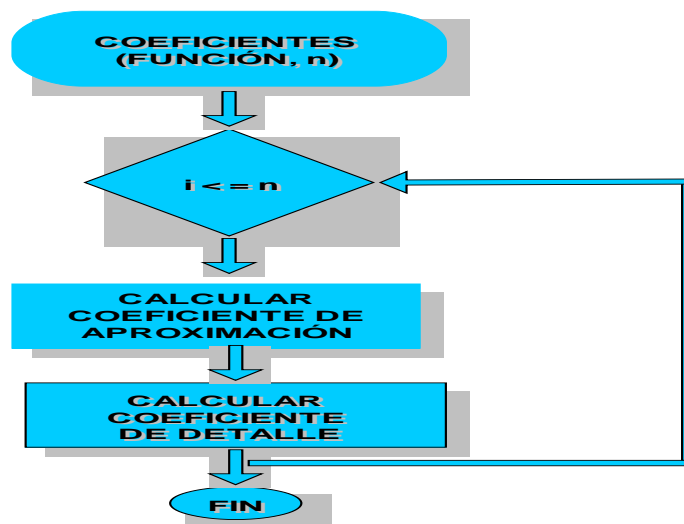
canal correspondiente a un movimiento y luego se da la opción mover para ver el movimiento y el cambio de color que indica el mismo.

4.4 FUNCIONES DE PREPROCESAMIENTO DE LA INFORMACIÓN

El análisis wavelet, utiliza como referencia una función conocida llamada wavelet madre que se utiliza como referencia para descomponer la señal en los componentes de aproximación y detalle. Dicha función se debe seleccionar de tal forma que tenga una similitud con la entrada a procesar.

Para el preprocesamiento de la información, se debe definir la frecuencia de muestreo y el tamaño de la información. Luego se debe definir la función Wavelet madre a utilizar y finalmente el procesamiento mismo para obtener los datos de aproximación y detalle correspondiente al dato de entrada. La secuencia a realizar para el análisis Wavelet, se observa en la figura 17.

Figura 17. Diagrama de flujo procesamiento wavelet



Donde w es la familia wavelet madre, la cual se debe escoger teniendo en cuenta que esta debe presentar una gran similitud con la señal a representar. En esta aplicación se usa 'sym3' (Figura 18), 'sym6' (Figura 19) y 'db4' (Figura 20). La

variable res, corresponde al nivel de detalle. En este proyecto se trabajó con análisis de resolución entre 5 y 8. La variable s corresponde a la señal de entrada. En el ciclo for lo que se hace es almacenar los resultados del análisis en vectores que corresponden al vector de aproximación o detalle correspondiente a cada resolución.

Figura 18. Wavelet madre Sym 3




Figura 19. Wavelet madre Sym 6.





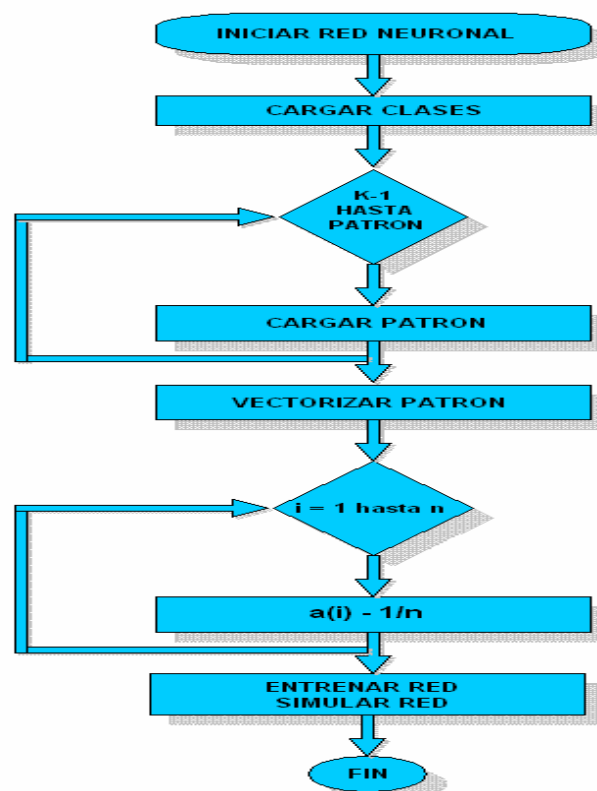
Figura 20. Wavelet madre daubichies 4



4.5 FUNCIONES DE PROCESAMIENTO DE DATOS

Para el procesamiento de datos, se utiliza una red neuronal de tipo LVQ, debido a que este es el mejor modelo neuronal de la actualidad, ya que utiliza un aprendizaje competitivo, que tiene en cuenta los conceptos de vecindad del algoritmo de entrenamiento tradicional de kohonen y que para su estructura se construye en su capa de entrada con el tamaño de la frecuencia de muestreo a utilizar, en la capa oculta se seleccionó un numero de neuronas cercano a la mitad del vector de entrada y en la capa de salida el numero de clases a obtener, que en el caso de esta aplicación es cinco. Para implementar la misma, se está utilizando el toolbox de Matlab correspondiente a neural network y su diagrama de flujo se puede ver en la figura 21.

Figura 21 Diagrama de flujo de la red LVQ en matlab




El código lo primero que hace es leer el archivo de texto que contiene las clases en que van a ser clasificados los datos aprendidos, para almacenarlos en la variable clases. Luego se lee uno a uno los patrones a aprender desde archivos de texto, donde están almacenados los resultados del preprocesamiento. Se asocian los patrones de entrada con las clases y se crea una nueva red lvq, se selecciona el ciclo máximo de entrenamientos y luego se procede a entrenar la red.

La función sim ejecuta la red con el entrenamiento obtenido ante un patrón de entrada específico y la función vec2ind, determina un índice correspondiente a la clase resultante, en el caso de la aplicación las clases son los números del 1 al 5 para indicar la dirección del movimiento y el clic.

4.6 CONTROL DEL MOUSE DESDE LA APLICACIÓN

Para el control del Mouse, se están utilizando funciones de java, que se pueden conectar con el código en lenguaje M, permitiendo interactuar con los resultados obtenidos del procesamiento, como se observa en la figura 22.

Figura 22. Diagrama de flujo manejo del Mouse



Donde se usa la librería de java Robot que se encarga de crear el movimiento del Mouse. Se define la variable ScreenSize que se encarga de calcular el tamaño de la resolución para llevar el puntero con la función mouseMove al centro de la pantalla y desde allí empezar el movimiento cíclico en la dirección que se ha calculado por el clasificador para mostrar gráficamente el movimiento del Mouse.

4.7 CONCLUSIONES

- La programación en el lenguaje M de Matlab, tiene la ventaja, de permitir utilizar los toolbox de esta herramienta, así como código externo escrito en Java u otros lenguajes. La GUI construida para el procesamiento de las señales permite que el usuario seleccione la frecuencia de muestreo; el tamaño de la ventana de tiempo, es decir, el tamaño de la señal que va a tomar; el número máximo de iteraciones que realizará el algoritmo de traslación (necesario sólo para el análisis lineal del discriminante paso a paso).
- Debido a la forma de la señal EEG, es necesario seleccionar un análisis con una wavelet madre Daubechies o sym, debido a su parecido con esta señal. Esto permite tener una mejor clasificación de señales, detección de puntos característicos, detección de ondas de estas medidas en el dominio tiempo-frecuencia.
- Para la clasificación de datos, el tipo de aprendizaje de redes neuronales mas adecuado, es el de aprendizaje competitivo por ser el mas confiable, además el modelo LVQ en particular, combina el aprendizaje supervisado y no supervisado, para clasificar adecuadamente datos con componentes y características dispares.

5. PRUEBAS Y RESULTADOS

5.1 INTRODUCCIÓN

Después de escoger un protocolo de pruebas que permitiera tomar la información necesaria y de tener la base de datos con la información requerida para esta investigación, se realizaron un conjunto de pruebas de dicha información, utilizando las wavelets Sym3, sym6 y db4, para información relacionada con el movimiento de la mano derecha y con visualización de señales de dirección. Cuando el entrenamiento de la red neuronal estuvo finalizado, se prosiguió con el uso de la red entrenada en el módulo de verificación, que permitió obtener la matriz de respuesta que mostró los resultados expuestos en este capítulo.

Posteriormente, se comprobó el funcionamiento del sistema usando los mejores resultados, cambiando la estructura de la red neuronal utilizada para verificar si modificar la arquitectura de dicha red, afectaba o no el resultado obtenido. Finalmente se verificó el funcionamiento con nuevas muestras y se muestra una tabla que compara la técnica presentada en este trabajo comparada con otras técnicas.

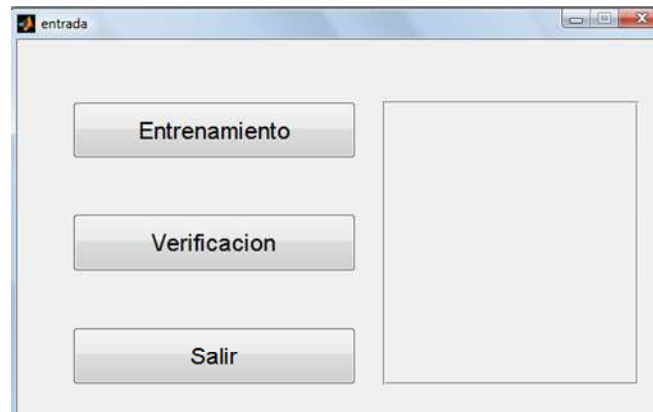
5.2 DESCRIPCIÓN DE LAS PRUEBAS

La toma de muestras en los participantes, fue grabada en vídeo para sincronizar las órdenes con los datos tomados, los cuales se almacenaron y luego se marcaron los tiempos en los que se presentaron los eventos a utilizar.

Desde la interfaz de entrada de la aplicación (Ver figura 23) se selecciono el módulo de entrenamiento y allí el de preprocesamiento al que se llega desde la ventana principal del modulo (Figura 24). En esta se configuró la frecuencia de muestreo a los 512 Hz correspondientes al equipo de electroencefalografía, luego


se seleccionó la wavelet con la que se realizó el análisis, teniendo disponibles para el uso la sym3, la db4 y la sym6.

Figura 23. Entrada del programa.



Una vez realizado el análisis wavelet, los datos son salvados con la opción “Salvar patrón”, para poder ser utilizadas posteriormente en el entrenamiento de la red neuronal, teniendo en cuenta que el análisis de resolución n , entrega $2n$ patrones correspondientes a los n de detalle y los n de aproximación. De estos valores se eliminan los que contienen muy pocos puntos debido a que su información puede ser insuficiente y producir mayor probabilidad de error en la clasificación. Para este estudio se eliminaron los resultados de los coeficientes 1 para aproximación y detalle, así como 2 y 3 para aproximación.


Figura 24. Ventana principal del programa



La selección de los parámetros de la RNA, se realizó a través del menú correspondiente, donde se escoge el número de patrones a aprender, el nombre de los archivos que contienen la información y el número de clases para clasificar. Una vez realizado el entrenamiento de la red, se pueden almacenar los parámetros de la aplicación en un archivo .mat, para su posterior reutilización.

Una vez realizado el entrenamiento se puede cargar el módulo de verificación (Figura 25) que tiene como función cargar un vector de un segundo de duración correspondiente a una señal cualquiera de alguno de los canales disponibles y luego se le realiza el análisis wavelet correspondiente al entrenamiento de la RNA.

Figura 25. Módulo de verificación



A continuación se verifica cada uno de los patrones wavelet, con la red neuronal, excluyendo los vectores correspondientes al coeficiente de detalle 1 y a los de aproximación 1, 2 y 3, se incrementa un contador correspondiente a cada una de las salidas posibles y si el mayor de estos contadores sobrepasa un umbral (en este caso con un valor igual al 50 % de los patrones comprobados, es decir 6, debido a que el numero de patrones que se comprueban, corresponde a 5 de

aproximación y 7 de detalle) se envía la orden de movimiento del mouse en la dirección correspondiente.

5.3 RESULTADOS CON LA WAVELET SYM3

La primera prueba que se realizó, correspondió al entrenamiento de una red neuronal con 258 neuronas en la capa oculta, 200 ciclos de entrenamiento y la información correspondiente a un canal a la vez, donde el estímulo fue la imagen de las tarjetas correspondientes al movimiento esperado (Ver Anexo 1). Luego se realizó la prueba con otros datos correspondientes al mismo canal. Durante la fase de verificación los mejores resultados fueron los mostrados en la tabla 1 y 2.

Tabla 1. Respuesta del canal 11 con la wavelet sym3 para estímulo visual

RESPUESTA	ESTIMULO				
	ARRIBA	ABAJO	IZQUIERDA	DERECHA	CENTRO
ARRIBA	50	30,56	0	8,33	11,11
ABAJO	2,78	47,22	33,33	8,33	8,33
IZQUIERDA	16,67	25	30,56	19,44	8,33
DERECHA	5,56	13,89	0	69,44	11,11
CENTRO	0	27,78	0	0	72,22

Tabla 2. Respuesta del canal 12 con la wavelet sym3 para estímulo visual

RESPUESTA	ESTIMULO				
	ARRIBA	ABAJO	IZQUIERDA	DERECHA	CENTRO
ARRIBA	52,78	33,33	8,33	2,78	2,78
ABAJO	41,67	55,56	2,78	0,00	0,00
IZQUIERDA	11,11	22,22	38,89	13,89	13,89
DERECHA	27,78	13,89	5,56	38,89	13,89
CENTRO	0,00	8,33	0,00	0,00	91,67

De esta primera prueba se puede obtener unos resultados que muestran una primera relación de los datos obtenidos con cada uno de los patrones que se

pretendía aprender así.

Como se puede notar en el anexo 1, el canal 1 clasifica de una forma aceptable la orden abajo con un valor de 69,4 %, mientras que otras órdenes como izquierda no son adecuadamente clasificadas por la aplicación, pudiéndose notar que la información que recibe este canal, no es adecuada para esta clasificación, o al menos con el análisis wavelet sym 3 de orden 8, seleccionado de esta resolución debido al uso de wavelet discretas y una frecuencia de muestreo de 512 Hz.

En el anexo 5 se puede ver el resultado de los demás canales a esta wavelet y de allí se puede observar que el mejor resultado se obtuvo para el canal 7 en promedio con 57,2 % para todas las señales, pero respondiendo mejor para la señal derecha que para las demás con valores de 72,2%; el canal 8 con un 66,6% a la señal izquierda; el canal 6 con un porcentaje del 91,7 respondió mejor a la señal centro y finalmente la orden arriba fue mejor clasificada con el canal 2 con un valor de 72,2%.

La siguiente prueba que se realizó, con las mismas características de la red neuronal, fue tomar como estímulo el movimiento mismo de la mano derecha ante las órdenes correspondientes. En la fase de verificación los resultados fueron los siguientes.

Tabla 3. Respuesta del canal 11 con la wavelet sym3 para movimiento

RESPUESTA	ESTIMULO				
	ARRIBA	ABAJO	IZQUIERDA	DERECHA	CENTRO
ARRIBA	50,00	5,56	19,44	11,11	13,89
ABAJO	27,78	41,67	2,78	27,78	0,00
IZQUIERDA	13,89	11,11	47,22	22,22	5,56
DERECHA	0,00	11,11	0,00	63,89	25,00
CENTRO	0,00	8,33	2,78	0,00	55,56

Tabla 4. Respuesta del canal 12 con la wavelet sym3 para movimiento

RESPUESTA	ESTIMULO				
	ARRIBA	ABAJO	IZQUIERDA	DERECHA	CENTRO
ARRIBA	38,89	2,78	16,67	5,56	36,11
ABAJO	25,00	47,22	2,78	11,11	13,89
IZQUIERDA	0,00	11,11	47,22	13,89	27,78
DERECHA	13,89	22,22	0,00	55,56	8,33
CENTRO	0,00	4,17	20,83	29,17	45,83

5.4 RESULTADOS CON LA WAVELET SYM 6

La segunda prueba que se realizó correspondió al entrenamiento de una red neuronal de características idénticas, pero utilizando como entradas los datos preprocesados con las wavelets sym 6, obteniéndose los siguientes resultados. ante los estímulos con imágenes.

Tabla 5. Respuesta del canal 8 con la wavelet sym6 para estimulo visual

RESPUESTA	ESTIMULO				
	ARRIBA	ABAJO	IZQUIERDA	DERECHA	CENTRO
ARRIBA	50,00	16,67	19,44	0,00	13,89
ABAJO	2,78	55,56	41,67	0,00	0,00
IZQUIERDA	2,78	11,11	83,33	2,78	0,00
DERECHA	16,67	8,33	33,33	25,00	16,67
CENTRO	16,67	13,89	22,22	0,00	47,22

Tabla 6. Respuesta del canal 11 con la wavelet sym6 para estimulo visual

RESPUESTA	ESTIMULO				
	ARRIBA	ABAJO	IZQUIERDA	DERECHA	CENTRO
ARRIBA	55,56	19,44	22,22	2,78	0,00
ABAJO	13,89	52,78	30,56	2,78	0,00
IZQUIERDA	8,33	22,22	55,56	13,89	0,00
DERECHA	8,33	16,67	11,11	63,89	0,00
CENTRO	13,89	33,33	27,78	11,11	13,89

De aquí se puede observar que no se obtuvo un resultado completo que clasificara adecuadamente los cinco tipos de señales, respondiendo mejor nuevamente el canal 11 a las señales correspondientes a los estímulos visuales.

Los mejores resultados por cada señal se encontraron así: arriba en el canal 6 con el porcentaje 80.56%, abajo el canal 1 con el porcentaje 69.44%, izquierda el canal 8 con el porcentaje 83,33%, derecha el canal 11 con el porcentaje 63.89%, y centro el canal 12 con el porcentaje. 83.33%

Ante los movimientos, los mejores resultados obtenidos se localizaron en el canal 8 y 11 del sistema de referencia y fueron los mostrados en las tablas 7 y 8.

Tabla 7. Respuesta del canal 8 con la wavelet sym6 para movimiento

RESPUESTA	ESTIMULO				
	ARRIBA	ABAJO	IZQUIERDA	DERECHA	CENTRO
ARRIBA	50,00	0,00	13,89	5,56	30,56
ABAJO	11,11	8,33	72,22	5,56	2,78
IZQUIERDA	5,56	0,00	80,56	0,00	13,89
DERECHA	13,89	0,00	11,11	66,67	8,33
CENTRO	11,11	0,00	11,11	0,00	77,78

Tabla 8. Respuesta del canal 11 con la wavelet sym6 para movimiento

RESPUESTA	ESTIMULO				
	ARRIBA	ABAJO	IZQUIERDA	DERECHA	CENTRO
ARRIBA	77,78	13,89	8,33	0,00	0,00
ABAJO	27,78	61,11	11,11	0,00	0,00
IZQUIERDA	36,11	11,11	52,78	0,00	0,00
DERECHA	8,33	22,22	19,44	36,11	13,89
CENTRO	13,89	22,22	25,00	0,00	38,89

Se puede observar que los resultados de este análisis empeoraron con respecto al análisis de la wavelet sym 3, pero sigue siendo el mejor resultado el del canal 11, aunque los porcentajes altos se notaron en el movimientos en el canal 8 con una confusión en los movimientos de abajo e izquierda.

5.5 RESULTADOS CON LA WAVELET DAUBICHIES 4

La última prueba de análisis realizada correspondió a la wavelet Daubechies 4, la cual es una wavelet que utiliza una función madre diferente a los dos análisis anteriores. La salida de este análisis ante los estímulos de imágenes, se puede apreciar en el anexo 2 y los canales que mejor fueron interpretados por el sistema, nuevamente fueron el canal 11 y el 12, como se puede observar en las tablas 9 y 10.

Tabla 9. Respuesta del canal 11 con la wavelet db4 para estímulo visual

RESPUESTA	ESTIMULO				
	ARRIBA	ABAJO	IZQUIERDA	DERECHA	CENTRO
ARRIBA	75,00	5,56	16,67	2,78	0,00
ABAJO	22,22	36,11	36,11	5,56	0,00
IZQUIERDA	25,00	13,89	55,56	5,56	0,00
DERECHA	13,89	2,78	11,11	58,33	13,89
CENTRO	33,33	8,33	11,11	16,67	30,56

Tabla 10. Respuesta del canal 12 con la wavelet db4 para estímulo visual

RESPUESTA	ESTIMULO				
	ARRIBA	ABAJO	IZQUIERDA	DERECHA	CENTRO
ARRIBA	50,00	27,78	16,67	2,78	2,78
ABAJO	36,11	55,56	8,33	0,00	0,00
IZQUIERDA	2,78	22,22	58,33	16,67	0,00
DERECHA	2,78	36,11	16,67	38,89	5,56
CENTRO	4,17	12,50	0,00	0,00	83,33

Los mejores resultados por cada señal se encontraron así: arriba en el canal 11 con el porcentaje 75%, abajo el canal 1 con el porcentaje 75%, izquierda el canal 4 con el porcentaje 61.11%, derecha el canal 11 con el porcentaje 58.33%, y centro el canal 12 con el porcentaje. 83.33%

Con los movimientos las respuestas fueron los observados en las tablas 11 y 12

Tabla 11. Respuesta del canal 7 con la wavelet db4 para movimiento

RESPUESTA	ESTIMULO				
	ARRIBA	ABAJO	IZQUIERDA	DERECHA	CENTRO
ARRIBA	69,44	2,78	0,00	16,67	11,11
ABAJO	2,78	61,11	0,00	25,00	11,11
IZQUIERDA	19,44	5,56	27,78	22,22	25,00
DERECHA	19,44	0,00	27,78	41,67	11,11
CENTRO	5,56	8,33	0,00	13,89	72,22

Tabla 12. Respuesta del canal 11 con la wavelet db4 para movimiento

RESPUESTA	ESTIMULO				
	ARRIBA	ABAJO	IZQUIERDA	DERECHA	CENTRO
ARRIBA	52,78	5,56	13,89	27,78	0,00
ABAJO	27,78	41,67	2,78	27,78	0,00
IZQUIERDA	16,67	13,89	44,44	25,00	0,00
DERECHA	0,00	8,33	2,78	72,22	16,67
CENTRO	5,56	11,11	16,67	30,56	36,11

5.6 RESULTADOS AL MODIFICAR LA ESTRUCTURA DE LA RED NEURONAL

Se realizaron pruebas modificando la estructura de la red neuronal LVQ, para saber si mejoraba o disminuía la respuesta de la señal. Para tal prueba se escogió el canal y el análisis wavelet que en las pruebas anteriores había dado el mejor desempeño, correspondientes a la prueba de estímulo por imágenes en el análisis

con la wavelet sym3 con una resolución 8 y se obtuvo, lo observado en las tablas 13 y 14.

Tabla 13. Respuesta del canal 11 con una RNA con 358 neuronas en la capa oculta ante estímulo visual

RESPUESTA	ESTIMULO				
	ARRIBA	ABAJO	IZQUIERDA	DERECHA	CENTRO
ARRIBA	52,78	27,78	0,00	11,11	8,33
ABAJO	2,78	50,00	27,78	11,11	8,33
IZQUIERDA	22,22	27,78	27,78	19,44	2,78
DERECHA	5,56	2,78	0,00	80,56	11,11
CENTRO	0,00	11,11	0,00	5,56	83,33

Tabla 14. Respuesta del canal 11 con una RNA con 158 neuronas en la capa oculta ante estímulo visual

RESPUESTA	ESTIMULO				
	ARRIBA	ABAJO	IZQUIERDA	DERECHA	CENTRO
ARRIBA	47,22	0,00	36,11	2,78	13,89
ABAJO	5,56	13,89	61,11	11,11	8,33
IZQUIERDA	8,33	8,33	66,67	11,11	5,56
DERECHA	2,78	0,00	19,44	72,22	5,56
CENTRO	0,00	0,00	11,11	0,00	88,89

Las características que se observan al aplicar redes neuronales es que al aumentar nodos de las capas internas de la red responde mejor los estímulos centro y derecha sobre el mismo canal 11, pero al disminuir estas capas internas las respuestas en el mismo canal 11 aumenta en los estímulos derecha, izquierda y centro. Esto da como resultado que las capas ocultas distintas a las predeterminadas por la herramienta no responden de manera uniforme sobre todos los estímulos, de lo que puede concluirse que no es necesario el aumento o disminución de nodos internos de red.

5.7 VERIFICACIÓN CON NUEVAS MUESTRAS

Dado que el mejor resultado se obtuvo con la wavelet sym3 en los canales occipitales, durante el proceso de imaginación gráfica de la dirección del movimiento, se regresó a la clínica rosales para tomar un conjunto de nuevas muestras en las que se estimuló a los participantes con las mismas tarjetas, para grabar las señales eeg. El experimento cambió en dos aspectos, se redujo la frecuencia de muestreo a 256 y se utilizaron gorros del sistema 10-20, de donde se almacenaron las señales correspondientes a los canales f3, f4, c3, c4, o1 y o2; en el sistema original de medida del experimento, correspondía a los canales 3, 6, 4, 7, 11 y 12 respectivamente.

Los resultados obtenidos fueron los mostrados en las tablas 15 y 16:

Tabla 15. Porcentaje de respuesta del canal 11 (o1) con una red neuronal con 258 neuronas en la capa oculta

RESPUESTA	ESTIMULO				
	ARRIBA	ABAJO	IZQUIERDA	DERECHA	CENTRO
ARRIBA	100,00	0,00	0,00	0,00	0,00
ABAJO	11,11	50,00	0,00	8,33	30,56
IZQUIERDA	25,00	8,33	50,00	8,33	8,33
DERECHA	25,00	13,89	5,56	36,11	19,44
CENTRO	19,44	19,44	8,33	5,56	47,22

Se puede notar en estos resultados, que la respuesta fue correspondiente a la obtenida en las primeras pruebas, siendo nuevamente estos dos canales, los que dan la mejor respuesta ante el estímulo visual. A pesar de haber disminuido la frecuencia de muestreo.

Tabla 16. Porcentaje de respuesta del canal 12 (o2) con una red neuronal con 258 neuronas en la capa oculta

RESPUESTA	ESTIMULO				
	ARRIBA	ABAJO	IZQUIERDA	DERECHA	CENTRO
ARRIBA	97,22	0,00	0,00	2,78	0,00
ABAJO	8,33	36,11	11,11	11,11	33,33
IZQUIERDA	22,22	0,00	66,67	2,78	8,33
DERECHA	0,00	2,78	27,78	44,44	25,00
CENTRO	8,33	8,33	8,33	12,50	62,50

5.8 COMPARACIÓN CON OTRAS TÉCNICAS

La tabla 17 muestra el resultado comparativo de la técnica empleada en esta investigación, comparada con los trabajos citados en el apartado de antecedentes.

Tabla 17. Comparación de técnicas para BCI

Técnica	Electrodos	Tipo de clasificador	Señales a clasificar	Aciertos
Nakayama	6	Transformada rápida de Fourier (FFT)	6 tareas mentales	64% y el 74%
Pei	3	Wavelet de Morlet	2 movimientos	91,43%
Wang	2	FFT	detección de movimiento	87%
Trejo	12 EEG + EOG	Densidad espectral de potencia	movimiento cursor	58% y el 88%.
Deng	3	Red neuronal Backpropagation	2 movimientos	72.2 %
Rasmussen	3	Filtros IIR para frecuencias	2 tareas	72%
Rasmussen	3	Filtros IIR para frecuencias	4 tareas	45%
Vélez - Saldarriaga	10	Wavelet Sym3 y Red neuronal LVQ	5 tareas	53% y el 61%

De esta tabla se puede observar que el trabajo de Nakamura, se hace un análisis netamente frecuencial para determinar desde 6 entradas la respuesta de que

representa una acción en la región cerebral específica a la tarea a verificar, por ejemplo, que las tareas motrices se verifican por un cambio de frecuencia en la corteza motora, que las tareas de imaginación por un cambio de frecuencia en la región occipital, que las tareas de creatividad muestran actividad en la región prefrontal, etc. En el trabajo de Pei se realiza un análisis en el dominio tiempo-frecuencia que se ve limitado en el número de señales a clasificar en solo dos, ubicando 3 electrodos en la corteza motora. En el trabajo de Wang que utiliza dos electrodos, solo detecta a través del análisis de frecuencia si se efectúa movimiento o no. El trabajo de Trejo presenta una interfaz que deja de ser totalmente Cerebro-Computador, para ser una interfaz que utiliza electrooculografía como medio de entrada al dar el movimiento de los ojos, la guía para el control del cursor, teniendo las señales EEG, solo como referencia para indicar actividad. Deng utiliza el clasificador neuronal clásico, Backpropagation, como elemento de procesamiento de las tres señales de entrada, para determinar solo 2 movimientos específicos. Rasmussen presenta un resultado interesante al explicar con su trabajo que al incrementar el número de tareas mentales a clasificar, se decrementa el porcentaje de éxito del sistema. Estos resultados muestran las bondades del clasificador desarrollado en este trabajo que al utilizar en forma conjunta el análisis tiempo-frecuencia y el clasificador neuronal LVQ, logra clasificar cinco tareas diferentes, con un porcentaje de resultado bueno comparado con los sistemas antes mencionados, el número de electrodos se utilizó para encontrar las regiones de mejor respuesta del sistema.

5.9 CONCLUSIONES

- Las funciones wavelet madre son usadas para caracterizar los detalles en una señal, en el análisis y las pruebas realizadas, se observó que la Wavelet madre sym 3, fue la que mejor respondió al procesamiento de la señal en EEG, mientras que la sym 6 fue la que peor lo hizo.

- En la elaboración de este proyecto, el cual está basado en la aplicación de métodos científicos y en los resultados de experiencias de análisis clínicos de señales cerebrales, se encontró que las señales producidas ante estímulos visuales, representaban mejor la información, que las producidas ante los movimientos de la mano en la dirección correspondiente; ya que estas sólo dependen del pensamiento y no producen ruido adicional a la señal debido a la actividad muscular del usuario.
- La aplicación incorpora un algoritmo de procesamiento con redes neuronales LVQ para la clasificación de las señales. Esta se configura para utilizar un número de neuronas en la capa oculta y una frecuencia de muestreo altas; el hardware, es el limitante, necesitándose utilizar herramientas con mayor capacidad de procesamiento de información. Para este trabajo, se utilizó un equipo con procesador de 64 bits, así como el sistema operativo, la y una capacidad de memoria RAM de 4 Gigas.

6. OBSERVACIONES

- Las señales EEG son señales de una magnitud muy baja (microvolts), lo que hace que sean muy sensibles al ruido externo, siendo necesario para su medición, equipo electrónico muy especializado, el cual fue difícil de adquirir para este proyecto.
- Debido a que este proyecto pretende mostrar la clasificación de las señales EEG, sin incluir errores externos y debido al nivel alto de ruido de la señal, se decidió no fabricar los canales electroencefalográficos para la toma de muestras, pues el diseño y fabricación de este equipo incluiría más variables de error a tener en cuenta.
- Un problema añadido al enfoque no invasivo de la toma de muestras, es que las señales de EEG medidas son una superposición de actividades de todas las neuronas del cerebro y no corresponden a neuronas individuales. Este problema se puede mitigar hasta cierto punto, utilizando múltiples sensores.
- Los equipos de electroencefalografía se localizan principalmente en las clínicas especializadas en neurología, donde su disponibilidad, se encuentra limitada por la afluencia de pacientes. Esto hizo que a pesar de encontrar disposición de los médicos encargados de clínicas en Cali, Tulúa y Pereira, solo en esta última ciudad se pudiera encontrar una disponibilidad del equipo para la toma de muestras.
- Debido a la cantidad de cálculos que involucran el entrenamiento de las redes neuronales LVQ, con un número de 258 neuronas ocultas y 200 ciclos de actualización de pesos, se requiere un sistema de cómputo avanzado para disminuir el tiempo de procesamiento de los mismos; para este trabajo se utilizó un equipo de cómputo de alto rendimiento y un nivel de procesamiento mayor, y con una capacidad de memoria suficiente, con sistema operativo Linux de 64 bits. Con esta configuración del computador, el entrenamiento de la red neuronal tarda en entrenarse 7 minutos; con

equipos de cómputo de menor rendimiento y características menores pueden llegar a tardar hasta 22 minutos.

7. CONCLUSIONES GENERALES

- Por medio de la aplicación desarrollada, se logró encontrar una forma de clasificar las señales EEG y utilizar estas para controlar el cursor en la pantalla del computador, mediante la utilización de diferentes herramientas matemáticas como las Wavelets y las RNA.
- Utilizando la red neuronal LVQ (Learning Vector Quantification), con un número de neuronas ocultas equivalente a aproximadamente la mitad de la longitud del vector muestreado que representa la señal de entrada, se logró clasificar las señales adecuadamente para seleccionar el movimiento que correspondería al de la simulación del Mouse.
- La finalidad del trabajo de investigación es crear una representación manejable y significativa de la señal EEG original, con miras a maximizar el éxito potencial de la fase de clasificación y a su vez el rendimiento global del sistema. Para esto, se ha usado la transformada Wavelet y se encontró como mejor referencia la wavelet madre Sym 3, ya que en los resultados demostraron que es la que mejor logra filtrar de una forma adecuada las señales de entrada y eliminar las componentes de frecuencia que no aportaban información relevante para la clasificación de dichas señales; en cambio la wavelet Sym 6 entregó una representación mas confusa de la información presentada.
- Con las mismas transformaciones wavelet sym 3, se logró obtener un detalle mayor de la señal de entrada obteniendo mejores resultados en la clasificación de las mismas.
- Contrario a lo encontrado en la mayoría de la documentación leída previamente donde se centraba en trabajos correspondientes al uso de la zona sensomotora, en este proyecto se evidenció que los canales más relevantes son el 11 y 12 en nuestro sistema de medida. Estos canales corresponden a la región del cerebro encargada de la imaginación visual y no a la que entrega las ordenes a los diferentes músculos del cuerpo.

- Después de comprobar los diferentes datos de entrada y comparando la respuesta con los diferentes procesamientos utilizados, se encontró que las señales que presentaron menor error fueron las correspondientes a la orden centro.
- Debido a que las señales de aproximación y detalle de niveles bajos, tienen muy pocos puntos, se puede notar que estas señales, no contienen suficiente información para una adecuada clasificación y que además pueden generar confusión para el análisis, siendo mejor eliminarlos.
- La diferencia entre las señales generadas en la región occipital y la corteza motora es que la señal producida en el occipital, correspondiente a la visualización de movimiento, es más notoria, siendo más eficiente el análisis de las señales de dicha región.
- Los resultados analizados determinan que los canales conectados en la parte de occipital del cerebro marcan una tendencia mayor en ambos protocolos para la toma de muestras (intención de movimiento y visualización del pensamiento).
- Se puede determinar que un nivel alto de concentración de los pacientes en la toma de muestras, permite garantizar una mejor respuesta al momento de la adquisición de información, proporcionando así una mejor clasificación de las señales.

8. PERSPECTIVAS FUTURAS DE TRABAJO

- Desarrollo de una interfaz de control del sistema operativo, que permita a través de un hardware que se conecte al PC, la interacción de las órdenes mentales permitiendo el movimiento del mouse y la apertura de programas.
- Implementación en hardware del sistema de control que permita controlar equipos electrónicos a través de las ondas mentales, utilizando hardware especializado que integre el análisis wavelet y las redes neuronales necesarias para la clasificación.
- Desarrollo de hardware y software para aplicaciones robóticas con movimientos controlados por la mente, a demás del diseño de prótesis y sillas de ruedas con la misma interfaz.

9. REFERENCIAS BIBLIOGRÁFICAS

BABILONI, F y otros. Brain Computer Interface: Estimation of Cortical Activity From Non Invasive High Resolution EEG Recordings. Brain Research Bulletin 75 (2008).

BALLESTEROS, Dora y otro. Software de Análisis de Energía en señales Electroencefalográficas Básicas en la Transformada Wavelet Discreta. Fundación Universitaria Gabriela Bertrán, 2005.

BENIMELI, Francesc. Clasificación de Señales EEG en un Sistema BCI, Informe Técnico ITI-SAC-016, 2006.

BESSERVE, Michel y otros. Non-invasive classification of cortical activities for brain computer interface: a variable selection approach. Proceedings of the 26th Annual International Conference of the IEEE EMBS San Francisco, CA, USA September 1-5, 2004.

BOSTANOV, Vladimir, Feature Extraction From Event-Related Brain Potentials With the Continuous Wavelet Transform and the t-Value Scalogram. IEEE transactions on biomedical engineering, VOL. 51, NO. 6, JUNE 2004.

BRECHET, Laurent y otros. Compression of Biomedical Signals With Mother Wavelet Optimization and Best-Basis Wavelet Packet Selection. IEEE transactions on biomedical engineering, vol. 54, no. 12, december 2007.

CINCOTTI, Febo. Non-invasive brain computer interface system: Towards its application as assistive technology. Brain Research Bulletin 75 (2008).

CONDUIT, Rusell. Recording Electroencephalogram (EEG) and Auditory Related Potentials (ARPs) in Humans. Department of Psychology, Monash University, AUSTRALIA, 2000.

DELORME, ARNAUD. Eeglab tutorial, University of San Diego California, 2006.

DENG, J. HE, B. Classification of Imaginary Tasks from Three Channels of EEG by Using an Artificial Neural Network. Proceedings of the 25th Annual International Conference of the IEEE EMBS.2003.

FERNANDEZ, Enrique. Análisis de clasificadores bayesianos. Laboratorio de sistemas inteligentes, Universidad de Buenos aires. 2005.

GUGER Christoph y otros. Rapid Prototyping of an EEG-Based Brain–Computer Interface (BCI). IEEE transactions on neural systems and rehabilitation engineering, vol. 9, no. 1, march 2001.

GUGER, C. y otros. How Many People are Able to Operate an EEG-Based Brain-Computer Interface (BCI)?. IEEE transactions on neural systems and rehabilitation engineering, VOL. 11, NO. 2, JUNE 2003.

GUO-ZHENG, Yan y otros. EEG feature extraction based on wavelet packet decomposition for brain computer interface. www.sciencedirect.com, Measurement 41 .2008.

GUYTON ARTHUR C. Tratado de fisiología medica, 11 edición, Elsevier España, 2006.

KACHENOURA, Amar y otros. ICA: A Potential Tool for BCI Systems [An in-depth look]. IEEE signal processing magazine [57] january 2008.

KAMEN, EDWARD W, HECK, BONNIE S. Fundamentals of signals and Systems using the web and Matlab, Prentice hall, 2007.

KENDEL E.R., SCHWARTZ J.H., JESSELL T.M. Principios de Neurociencia., 4ª Edición.Madrid McGraw-Hill, 2001.

KOURO, Samir, MUSALEM, Rodrigo. Tutorial introductoria a la teoría Wavelet. Técnicas modernas en automática.

KRUIF, Bas J. y otros. Classification of Imagined Beats for use in a Brain Computer Interface. Proceedings of the 29th Annual International Conference of the IEEE EMBS Internationale, Lyon, France August 23-26, 2007.

LABARGA GUTIÉRREZ, Alberto. Clasificación de Señales Encefalográficas con Redes Neuronales, Departamento de Ingeniería Eléctrica y Electrónica - Universidad Pública de Navarra.

LAN, Tian y otros. Salient EEG Channel Selection in Brain Computer Interfaces by Mutual Information Maximization. Proceedings of the 2005 IEEE Engineering in Medicine and Biology 27th Annual Conference Shanghai, China, September 1-4, 2005.

LEBEDEV, M. A. y NICOLELIS, M. A. Brain-machine interfaces: past, present and future. Trends inNeurosciences, 29, 536-546. 2006.

LEE, Yong Hee, KIM, Sun I. y LEE, Doo Soo. Estimation of evoked potentials based on the wavelet analysis. Proceedings - 19th International Conference - IEEE/EMBS Oct. 30 - Nov. 2, 1997.

LLAMOSA RINCÓN, LUÍS ENRIQUE. Diseño de canales para la detección de biopotenciales, Universidad Tecnológica de Pereira, 2005.

MA, Sheng. Modeling Heterogeneous Network Traffic in Wavelet Domain. IEEE/ACM transactions on networking, vol. 9, no. 5, october 2001.

MALLAT STÉPHANE. A wavelet tour of signal processing, Elsevier USA, 1999.

MARTÍN, José L., PALAZUELOS Sira E. Estudio comparativo de dos técnicas de procesamiento de señales eeg para la discriminación de estados mentales, Dpto. de Electrónica. Universidad de Alcalá. Madrid. España.

MILONE D., RUFINER H., ACEVEDO R., Di Persia L., Torres H., Introducción a las Señales y a los Sistemas Discretos. EDUNER. 2006.

MOORE, HOLLY. Matlab para ingenieros, Prentice Hall. 2007.

NAKAYAMA, Kenji. A Brain Computer Interface Based on FFT and Multilayer Neural Network - Feature Extraction and Generalization. Proceedings of 2007 International Symposium on Intelligent Signal Processing and Communication Systems Nov.28-Dec.1, 2007.

PARIKH, Prachi y MICHELI-TZANAKOU, Evangelia. Detecting Drowsiness While Driving Using Wavelet Transform. Proceedings IEEE. 2004.

PEI, Xiaomei. Classification of left and right hand motor imagery tasks based on EEG frequency component selection. Proceedings of 2007 International Symposium on Intelligent Signal Processing and Communication Systems Nov.28-Dec.1, 2007.

PLONSEY, Robert y otro. Bioelectricity A Quantitative Approach. Third Edition, Springer, 2007.

POLIKAR, Robi y otros. Multiresolution wavelet analysis and ensemble of classifiers for early diagnosis of alzheimer disease. IEEE V - 389 ICASSP 2005.

RANGAYYAN, RANGARAJ M. Biomedical signal análisis, IEEE, 2002.

RASMUSSEN, Robert G. y otros. Accuracy of a Brain-Computer Interface in Subjects with Minimal Training. Department of Biomedical Engineering, Johns Hopkins University Baltimore, MD 21205IEEE. 2006.

SÁNCHEZ, Roberto Hornero Sánchez. Procesado de señales biomédicas, E.T.S. Ingenieros de Telecomunicación, Universidad de Valladolid, 2008.

SUN, Shialiang, ZHANG, Changshui. Assessing features for electroencephalographic signal categorization. IEEE V - 417 ICASSP 2005.

TREJO, L. J.; ROSIPAL, R. and MATTHEWS, B. "Braincomputer interfaces for 1-D and 2-D cursor control: designs using volitional control of the EEG spectrum or steady-state visual evoked potentials". IEEE Transactions on Neural Systems and Rehabilitation Engineering, vol. 14, No. 2, June 2006.

VAN DRONGELEN, WIM. Signal processing for neuroscients, AP, 2008.


WANG, Tao. Classification of Motor Imagery EEG Patterns and Their Topographic Representation. Proceedings of the 26th Annual International Conference of the IEEE EMBS San Francisco, CA, USA September 1-5, 2004.

WINDHORST, Uwe. Modern Techniques in Neuroscience Research. Springer_Verlag. 1999

XU, Neng y otros. Enhancing P300 Wave Detection Using ICA-Based Subspace Projections for BCI Applications. IEEE transactions on biomedical engineering, VOL. 51, NO. 6, JUNE 2004.

10. ANEXOS

ANEXO 1. FORMATOS PRESENTADOS A LOS PACIENTES, PARA IMAGINAR LOS MOVIMIENTOS.



ANEXO 2. CÓDIGO CORRESPONDIENTE AL PROCESAMIENTO WAVELET EN MATLAB

```
[c,l] = wavedec(s,res,w);  
for i = 1:res  
    A(i,:) = wrcoef('a',c,l,win,i);  
    D(i,:) = wrcoef('d',c,l,win,i);  
end
```

ANEXO 3. CÓDIGO RED NEURONAL LVQ EN MATLAB

```
clases=load(arcclases);
for k=1:numpat
    nombre=[nompatron,num2str(k),'.txt'];
    t=load(nombre);
    m(:,k)=t';
end
p = m;
Tc=clases;
T = ind2vec(clases);
targets = full(T);
n=size(targets);
ocultas=numnoculta;
for i=1:n(1)
    a(i)=1/n(1);
end
red2 = newlvq(minmax(p),ocultas,a);
red2.trainParam.epochs = 200;
red2 = train(red2,p,T);
Y = sim(red2,p);
Yc = vec2ind(Y);
```

ANEXO 4. MANEJO DEL MOUSE EN JAVA

```
import java.awt.Robot;
mouse = Robot;
screenSize = get(0, 'screensize');
mouse.mouseMove(screenSize(3)/2, screenSize(4)/2);
for i = 1: 300
```

```

mouse.mouseMove(screenSize(3)/2, screenSize(4)/2-i);
pause(0.00001);
end

```

ANEXO 5. RESULTADOS DE LOS CANALES 1 AL 12 PARA LA WAVELET SYM 3 CON UNA RNA DE 258 NEURONAS EN LA CAPA OCULTA Y 200 CICLOS DE APRENDIZAJE PARA ESTIMULO CON IMÁGENES.

Canal 1

	ARRIBA	ABAJO	IZQUIERDA	DERECHA	CENTRO
ARRIBA	47,22	22,22	27,78	2,78	0
ABAJO	0	69,44	13,89	16,67	0
IZQUIERDA	8,33	22,22	13,89	52,78	2,78
DERECHA	0	22,22	30,56	47,22	0
CENTRO	0	27,78	27,78	8,33	36,11

Canal 2

	ARRIBA	ABAJO	IZQUIERDA	DERECHA	CENTRO
ARRIBA	72,22	2,78	0	5,56	19,44
ABAJO	33,33	8,33	27,78	2,78	27,78
IZQUIERDA	33,33	5,56	19,44	27,78	13,89
DERECHA	47,22	0	0	27,78	25
CENTRO	11,11	0	5,56	0	83,33

Canal 3

	ARRIBA	ABAJO	IZQUIERDA	DERECHA	CENTRO
ARRIBA	41,67	19,44	0	2,78	36,11
ABAJO	61,11	19,44	0	13,89	5,56
IZQUIERDA	30,56	5,56	5,56	11,11	47,22
DERECHA	25	2,78	2,78	33,33	36,11
CENTRO	36,11	2,78	0	0	61,11

Canal 4

	ARRIBA	ABAJO	IZQUIERDA	DERECHA	CENTRO
ARRIBA	47,22	11,11	5,56	5,56	30,56
ABAJO	38,89	30,56	13,89	13,89	2,78
IZQUIERDA	52,78	25	0	11,11	11,11
DERECHA	47,22	2,78	25	22,22	2,78
CENTRO	36,11	13,89	0	0	50

Canal 5

	ARRIBA	ABAJO	IZQUIERDA	DERECHA	CENTRO
ARRIBA	36,11	22,22	0	5,56	36,11
ABAJO	19,44	50	0	0	30,56
IZQUIERDA	13,89	33,33	2,78	13,89	36,11
DERECHA	2,78	16,67	0	22,22	58,33
CENTRO	0	36,11	0	0	63,89

Canal 6

	ARRIBA	ABAJO	IZQUIERDA	DERECHA	CENTRO
ARRIBA	16,67	0	16,67	0	66,67
ABAJO	5,56	13,89	22,22	2,78	55,56
IZQUIERDA	11,11	0	33,33	16,67	38,89
DERECHA	5,56	0	0	33,33	61,11
CENTRO	8,33	0	0	0	91,67

Canal 7

	ARRIBA	ABAJO	IZQUIERDA	DERECHA	CENTRO
ARRIBA	36,11	33,33	13,89	2,78	13,89
ABAJO	8,33	50	36,11	5,56	0
IZQUIERDA	2,78	8,33	55,56	33,33	0
DERECHA	2,78	16,67	8,33	72,22	0
CENTRO	2,78	30,56	19,44	8,33	38,89

Canal 8

	ARRIBA	ABAJO	IZQUIERDA	DERECHA	CENTRO
ARRIBA	38,89	13,89	33,33	0	13,89
ABAJO	5,56	27,78	58,33	2,78	2,78
IZQUIERDA	11,11	13,89	66,67	8,33	0
DERECHA	8,33	0	36,11	27,78	27,78
CENTRO	8,33	0	33,33	8,33	50

Canal 11

	ARRIBA	ABAJO	IZQUIERDA	DERECHA	CENTRO
ARRIBA	50	30,56	0	8,33	11,11
ABAJO	2,78	47,22	33,33	8,33	8,33
IZQUIERDA	16,67	25	30,56	19,44	8,33
DERECHA	5,56	13,89	0	69,44	11,11
CENTRO	0	27,78	0	0	72,22

Canal 12

	ARRIBA	ABAJO	IZQUIERDA	DERECHA	CENTRO
ARRIBA	52,78	33,33	8,33	2,78	2,78
ABAJO	41,67	55,56	2,78	0	0
IZQUIERDA	11,11	22,22	38,89	13,89	13,89
DERECHA	27,78	13,89	5,56	38,89	13,89
CENTRO	0	8,33	0	0	91,67

ANEXO 6. RESULTADOS DE LOS CANALES 1 AL 12 PARA LA WAVELET SYM 3 CON UNA RNA DE 258 NEURONAS EN LA CAPA OCULTA Y 200 CICLOS DE APRENDIZAJE PARA ESTIMULO CON MOVIMIENTOS.

Canal 1

	ARRIBA	ABAJO	IZQUIERDA	DERECHA	CENTRO
ARRIBA	27,78	5,56	0	38,89	27,78
ABAJO	0	75	0	16,67	8,33
IZQUIERDA	0	25	25	30,56	19,44
DERECHA	13,89	11,11	0	44,44	30,56
CENTRO	0	11,11	0	19,44	69,44

Canal 2

	ARRIBA	ABAJO	IZQUIERDA	DERECHA	CENTRO
ARRIBA	47,22	22,22	8,33	0	22,22
ABAJO	27,78	47,22	13,89	0	11,11
IZQUIERDA	30,56	5,56	50	0	13,89
DERECHA	5,56	25	5,56	13,89	50
CENTRO	11,11	11,11	13,89	0	63,89

Canal 3

	ARRIBA	ABAJO	IZQUIERDA	DERECHA	CENTRO
ARRIBA	25	8,33	22,22	30,56	13,89
ABAJO	8,33	50	2,78	27,78	11,11
IZQUIERDA	0	13,89	38,89	41,67	5,56
DERECHA	0	5,56	0	66,67	27,78
CENTRO	5,56	22,22	2,78	27,78	41,67

Canal 4

	ARRIBA	ABAJO	IZQUIERDA	DERECHA	CENTRO
ARRIBA	22,22	27,78	2,78	0	47,22
ABAJO	0	50	30,56	0	19,44
IZQUIERDA	5,56	19,44	50	0	25
DERECHA	13,89	25	2,78	27,78	30,56
CENTRO	0	25	16,67	0	58,33

Canal 5

	ARRIBA	ABAJO	IZQUIERDA	DERECHA	CENTRO
ARRIBA	52,78	27,78	5,56	0	13,89
ABAJO	47,22	33,33	11,11	0	8,33
IZQUIERDA	30,56	16,67	41,67	0	11,11
DERECHA	16,67	16,67	27,78	13,89	25
CENTRO	16,67	19,44	8,33	0	55,56

Canal 6

	ARRIBA	ABAJO	IZQUIERDA	DERECHA	CENTRO
ARRIBA	75	5,56	19,44	0	0
ABAJO	50	22,22	16,67	2,78	8,33
IZQUIERDA	58,33	13,89	27,78	0	0
DERECHA	47,22	2,78	0	30,56	19,44
CENTRO	44,44	5,56	5,56	0	44,44

Canal 7

	ARRIBA	ABAJO	IZQUIERDA	DERECHA	CENTRO
ARRIBA	66,67	0	19,44	0	13,89
ABAJO	11,11	69,44	0	0	19,44
IZQUIERDA	38,89	16,67	36,11	0	8,33
DERECHA	27,78	13,89	0	27,78	30,56
CENTRO	11,11	2,78	0	0	86,11

Canal 8

	ARRIBA	ABAJO	IZQUIERDA	DERECHA	CENTRO
ARRIBA	69,44	19,44	0	2,78	8,33
ABAJO	0	63,89	27,78	2,78	5,56
IZQUIERDA	2,78	38,89	36,11	2,78	19,44
DERECHA	0	19,44	0	69,44	11,11
CENTRO	16,67	19,44	0	2,78	61,11

Canal 11

	ARRIBA	ABAJO	IZQUIERDA	DERECHA	CENTRO
ARRIBA	50	5,56	19,44	11,11	13,89
ABAJO	27,78	41,67	2,78	27,78	0
IZQUIERDA	13,89	11,11	47,22	22,22	5,56
DERECHA	0	11,11	0	63,89	25
CENTRO	0	8,33	2,78	0	55,56

Canal 12

	ARRIBA	ABAJO	IZQUIERDA	DERECHA	CENTRO
ARRIBA	38,89	2,78	16,67	5,56	36,11
ABAJO	25	47,22	2,78	11,11	13,89
IZQUIERDA	0	11,11	47,22	13,89	27,78
DERECHA	13,89	22,22	0	55,56	8,33
CENTRO	0	4,17	20,83	29,17	45,83

**ANEXO 7. RESULTADOS DE LOS CANALES 1 AL 12 PARA LA WAVELET
SYM 6 CON UNA RNA DE 258 NEURONAS EN LA CAPA OCULTA Y 200
CICLOS DE APRENDIZAJE PARA ESTIMULO CON IMÁGENES.**

Canal 1

	ARRIBA	ABAJO	IZQUIERDA	DERECHA	CENTRO
ARRIBA	41,67	33,33	8,33	2,78	13,89
ABAJO	16,67	69,44	0	13,89	0
IZQUIERDA	16,67	36,11	33,33	13,89	0
DERECHA	16,67	27,78	33,33	22,22	0
CENTRO	22,22	30,56	11,11	0	36,11

Canal 2

	ARRIBA	ABAJO	IZQUIERDA	DERECHA	CENTRO
ARRIBA	27,78	16,67	5,56	5,56	44,44
ABAJO	2,78	61,11	13,89	0	22,22
IZQUIERDA	5,56	13,89	27,78	13,89	38,89
DERECHA	11,11	2,78	8,33	22,22	55,56
CENTRO	2,78	2,78	13,89	0	80,56

Canal 3

	ARRIBA	ABAJO	IZQUIERDA	DERECHA	CENTRO
ARRIBA	52,78	25	5,56	0	16,67
ABAJO	36,11	41,67	19,44	0	2,78
IZQUIERDA	25	19,44	30,56	13,89	11,11
DERECHA	19,44	16,67	25	13,89	25
CENTRO	27,78	8,33	2,78	8,33	52,78

Canal 4

	ARRIBA	ABAJO	IZQUIERDA	DERECHA	CENTRO
ARRIBA	44,44	22,22	13,89	19,44	0
ABAJO	30,56	47,22	5,56	13,89	2,78
IZQUIERDA	11,11	16,67	33,33	27,78	11,11
DERECHA	5,56	19,44	16,67	27,78	30,56
CENTRO	8,33	13,89	16,67	22,22	38,89

Canal 5

	ARRIBA	ABAJO	IZQUIERDA	DERECHA	CENTRO
ARRIBA	72,22	2,78	0	8,33	16,67
ABAJO	36,11	27,78	19,44	16,67	0
IZQUIERDA	38,89	5,56	19,44	30,56	5,56
DERECHA	38,89	0	13,89	41,67	5,56
CENTRO	30,56	0	2,78	16,67	50

Canal 6

	ARRIBA	ABAJO	IZQUIERDA	DERECHA	CENTRO
ARRIBA	80,56	0	0	13,89	5,56
ABAJO	44,44	13,89	13,89	16,67	11,11
IZQUIERDA	38,89	0	19,44	25	16,67
DERECHA	30,56	0	0	47,22	22,22
CENTRO	22,22	0	2,78	27,78	47,22

Canal 7

	ARRIBA	ABAJO	IZQUIERDA	DERECHA	CENTRO
ARRIBA	38,89	16,67	27,78	2,78	13,89
ABAJO	33,33	38,89	27,78	0	0
IZQUIERDA	16,67	2,78	55,56	25	0
DERECHA	13,89	5,56	47,22	22,22	11,11
CENTRO	8,33	22,22	27,78	0	41,67

Canal 8

	ARRIBA	ABAJO	IZQUIERDA	DERECHA	CENTRO
ARRIBA	50	16,67	19,44	0	13,89
ABAJO	2,78	55,56	41,67	0	0
IZQUIERDA	2,78	11,11	83,33	2,78	0
DERECHA	16,67	8,33	33,33	25	16,67
CENTRO	16,67	13,89	22,22	0	47,22

Canal 11

	ARRIBA	ABAJO	IZQUIERDA	DERECHA	CENTRO
ARRIBA	55,56	19,44	22,22	2,78	0
ABAJO	13,89	52,78	30,56	2,78	0
IZQUIERDA	8,33	22,22	55,56	13,89	0
DERECHA	8,33	16,67	11,11	63,89	0
CENTRO	13,89	33,33	27,78	11,11	13,89

Canal 12

	ARRIBA	ABAJO	IZQUIERDA	DERECHA	CENTRO
ARRIBA	38,89	41,67	5,56	8,33	5,56
ABAJO	27,78	63,89	0	2,78	5,56
IZQUIERDA	5,56	38,89	36,11	19,44	0
DERECHA	16,67	19,44	8,33	50	5,56
CENTRO	0	12,5	0	4,17	83,33

ANEXO 8. RESULTADOS DE LOS CANALES 1 AL 12 PARA LA WAVELET SYM 6 CON UNA RNA DE 258 NEURONAS EN LA CAPA OCULTA Y 200 CICLOS DE APRENDIZAJE PARA ESTIMULO CON MOVIMIENTOS.

Canal 1

	ARRIBA	ABAJO	IZQUIERDA	DERECHA	CENTRO
ARRIBA	55,56	0	16,67	19,44	8,33
ABAJO	16,67	50	11,11	19,44	2,78
IZQUIERDA	19,44	13,89	58,33	5,56	2,78
DERECHA	36,11	2,78	5,56	33,33	22,22
CENTRO	13,89	0	5,56	22,22	58,33

Canal 2

	ARRIBA	ABAJO	IZQUIERDA	DERECHA	CENTRO
ARRIBA	36,11	27,78	0	16,67	19,44
ABAJO	27,78	55,56	0	11,11	5,56
IZQUIERDA	27,78	19,44	22,22	22,22	8,33
DERECHA	0	22,22	0	55,56	22,22
CENTRO	0	13,89	0	25	61,11

Canal 3

	ARRIBA	ABAJO	IZQUIERDA	DERECHA	CENTRO
ARRIBA	47,22	5,56	25	5,56	16,67
ABAJO	16,67	30,56	11,11	11,11	30,56
IZQUIERDA	19,44	5,56	36,11	13,89	25
DERECHA	19,44	0	13,89	47,22	19,44
CENTRO	8,33	25	0	11,11	55,56

Canal 4

	ARRIBA	ABAJO	IZQUIERDA	DERECHA	CENTRO
ARRIBA	22,22	33,33	0	0	44,44
ABAJO	0	50	33,33	0	16,67
IZQUIERDA	0	13,89	66,67	2,78	16,67
DERECHA	13,89	33,33	8,33	27,78	16,67
CENTRO	0	38,89	11,11	0	50

Canal 5

	ARRIBA	ABAJO	IZQUIERDA	DERECHA	CENTRO
ARRIBA	55,56	30,56	13,89	0	0
ABAJO	30,56	55,56	13,89	0	0
IZQUIERDA	13,89	22,22	63,89	0	0
DERECHA	2,78	30,56	25	27,78	13,89
CENTRO	0	30,56	19,44	0	50

Canal 6

	ARRIBA	ABAJO	IZQUIERDA	DERECHA	CENTRO
ARRIBA	83,33	16,67	0	0	0
ABAJO	55,56	30,56	13,89	0	0
IZQUIERDA	55,56	19,44	22,22	0	2,78
DERECHA	47,22	8,33	0	27,78	16,67
CENTRO	44,44	13,89	0	0	41,67

Canal 7

	ARRIBA	ABAJO	IZQUIERDA	DERECHA	CENTRO
ARRIBA	69,44	0	0	27,78	2,78
ABAJO	16,67	50	0	25	8,33
IZQUIERDA	19,44	0	36,11	8,33	36,11
DERECHA	25	8,33	0	47,22	19,44
CENTRO	5,56	0	0	25	69,44

Canal 8

	ARRIBA	ABAJO	IZQUIERDA	DERECHA	CENTRO
ARRIBA	50	0	13,89	5,56	30,56
ABAJO	11,11	8,33	72,22	5,56	2,78
IZQUIERDA	5,56	0	80,56	0	13,89
DERECHA	13,89	0	11,11	66,67	8,33
CENTRO	11,11	0	11,11	0	77,78

Canal 11

	ARRIBA	ABAJO	IZQUIERDA	DERECHA	CENTRO
ARRIBA	77,78	13,89	8,33	0	0
ABAJO	27,78	61,11	11,11	0	0
IZQUIERDA	36,11	11,11	52,78	0	0
DERECHA	8,33	22,22	19,44	36,11	13,89
CENTRO	13,89	22,22	25	0	38,89

Canal 12

	ARRIBA	ABAJO	IZQUIERDA	DERECHA	CENTRO
ARRIBA	63,89	16,67	8,33	11,11	0
ABAJO	44,44	41,67	0	13,89	0
IZQUIERDA	19,44	11,11	36,11	33,33	0
DERECHA	22,22	25	0	52,78	0
CENTRO	20,83	8,33	4,17	66,67	0

ANEXO 9. RESULTADOS DE LOS CANALES 1 AL 12 PARA LA WAVELET DB4 CON UNA RNA DE 258 NEURONAS EN LA CAPA OCULTA Y 200 CICLOS DE APRENDIZAJE PARA ESTIMULO CON IMÁGENES.

Canal 1

	ARRIBA	ABAJO	IZQUIERDA	DERECHA	CENTRO
ARRIBA	44,44	36,11	5,56	2,78	11,11
ABAJO	11,11	75	0	13,89	0
IZQUIERDA	22,22	16,67	33,33	27,78	0
DERECHA	22,22	25	30,56	22,22	0
CENTRO	16,67	38,89	16,67	0	27,78

Canal 2

	ARRIBA	ABAJO	IZQUIERDA	DERECHA	CENTRO
ARRIBA	58,33	2,78	22,22	2,78	13,89
ABAJO	30,56	30,56	38,89	0	0
IZQUIERDA	27,78	2,78	47,22	13,89	8,33
DERECHA	33,33	5,56	22,22	22,22	16,67
CENTRO	19,44	0	38,89	0	41,67

Canal 3

	ARRIBA	ABAJO	IZQUIERDA	DERECHA	CENTRO
ARRIBA	58,33	0	2,78	5,56	33,33
ABAJO	44,44	22,22	22,22	0	11,11
IZQUIERDA	30,56	5,56	30,56	13,89	19,44
DERECHA	38,89	0	27,78	22,22	11,11
CENTRO	30,56	0	2,78	2,78	63,89

Canal 4

	ARRIBA	ABAJO	IZQUIERDA	DERECHA	CENTRO
ARRIBA	52,78	19,44	25	2,78	0
ABAJO	30,56	19,44	50	0	0
IZQUIERDA	19,44	0	61,11	16,67	2,78
DERECHA	27,78	0	38,89	25	8,33
CENTRO	5,56	0	30,56	2,78	61,11

Canal 5

	ARRIBA	ABAJO	IZQUIERDA	DERECHA	CENTRO
ARRIBA	61,11	0	19,44	5,56	13,89
ABAJO	44,44	25	16,67	0	13,89
IZQUIERDA	36,11	8,33	13,89	30,56	11,11
DERECHA	52,78	0	0	25	22,22
CENTRO	33,33	2,78	0	0	63,89

Canal 6

	ARRIBA	ABAJO	IZQUIERDA	DERECHA	CENTRO
ARRIBA	52,78	0	13,89	0	33,33
ABAJO	16,67	8,33	30,56	8,33	36,11
IZQUIERDA	8,33	0	25	19,44	47,22
DERECHA	8,33	5,56	13,89	25	47,22
CENTRO	5,56	5,56	0	13,89	75

Canal 7

	ARRIBA	ABAJO	IZQUIERDA	DERECHA	CENTRO
ARRIBA	55,56	5,56	22,22	2,78	13,89
ABAJO	30,56	36,11	33,33	0	0
IZQUIERDA	16,67	8,33	58,33	16,67	0
DERECHA	27,78	2,78	36,11	22,22	11,11
CENTRO	27,78	11,11	13,89	0	47,22

Canal 8

	ARRIBA	ABAJO	IZQUIERDA	DERECHA	CENTRO
ARRIBA	63,89	2,78	0	2,78	30,56
ABAJO	16,67	61,11	13,89	5,56	2,78
IZQUIERDA	19,44	11,11	41,67	5,56	22,22
DERECHA	30,56	5,56	0	30,56	33,33
CENTRO	22,22	11,11	0	8,33	58,33

Canal 11

	ARRIBA	ABAJO	IZQUIERDA	DERECHA	CENTRO
ARRIBA	75	5,56	16,67	2,78	0
ABAJO	22,22	36,11	36,11	5,56	0
IZQUIERDA	25	13,89	55,56	5,56	0
DERECHA	13,89	2,78	11,11	58,33	13,89
CENTRO	33,33	8,33	11,11	16,67	30,56

Canal 12

	ARRIBA	ABAJO	IZQUIERDA	DERECHA	CENTRO
ARRIBA	50	27,78	16,67	2,78	2,78
ABAJO	36,11	55,56	8,33	0	0
IZQUIERDA	2,78	22,22	58,33	16,67	0
DERECHA	2,78	36,11	16,67	38,89	5,56
CENTRO	4,17	12,5	0	0	83,33

ANEXO 10. RESULTADOS DE LOS CANALES 1 AL 12 PARA LA WAVELET DB4 CON UNA RNA DE 258 NEURONAS EN LA CAPA OCULTA Y 200 CICLOS DE APRENDIZAJE PARA ESTIMULO CON MOVIMIENTOS.

Canal 1

	ARRIBA	ABAJO	IZQUIERDA	DERECHA	CENTRO
ARRIBA	47,22	0	22,22	25	5,56
ABAJO	22,22	50	5,56	13,89	8,33
IZQUIERDA	5,56	13,89	72,22	8,33	0
DERECHA	36,11	0	5,56	36,11	16,67
CENTRO	5,56	0	5,56	19,44	69,44

Canal 2

	ARRIBA	ABAJO	IZQUIERDA	DERECHA	CENTRO
ARRIBA	61,11	16,67	0	22,22	0
ABAJO	44,44	44,44	0	11,11	0
IZQUIERDA	61,11	8,33	22,22	8,33	0
DERECHA	25	11,11	0	47,22	16,67
CENTRO	13,89	25	0	22,22	38,89

Canal 3

	ARRIBA	ABAJO	IZQUIERDA	DERECHA	CENTRO
ARRIBA	8,33	8,33	50	8,33	25
ABAJO	0	38,89	13,89	16,67	30,56
IZQUIERDA	0	0	83,33	11,11	5,56
DERECHA	0	5,56	5,56	75	13,89
CENTRO	0	16,67	5,56	22,22	55,56

Canal 4

	ARRIBA	ABAJO	IZQUIERDA	DERECHA	CENTRO
ARRIBA	22,22	13,89	5,56	0	58,33
ABAJO	0	33,33	38,89	0	27,78
IZQUIERDA	0	8,33	58,33	0	33,33
DERECHA	13,89	2,78	16,67	27,78	38,89
CENTRO	0	25	11,11	0	63,89

Canal 5

	ARRIBA	ABAJO	IZQUIERDA	DERECHA	CENTRO
ARRIBA	58,33	33,33	8,33	0	0
ABAJO	27,78	50	22,22	0	0
IZQUIERDA	13,89	25	61,11	0	0
DERECHA	19,44	41,67	22,22	13,89	2,78
CENTRO	2,78	30,56	19,44	0	47,22

Canal 6

	ARRIBA	ABAJO	IZQUIERDA	DERECHA	CENTRO
ARRIBA	38,89	25	30,56	2,78	2,78
ABAJO	25	33,33	38,89	2,78	0
IZQUIERDA	16,67	16,67	61,11	0	5,56
DERECHA	13,89	5,56	36,11	27,78	16,67
CENTRO	30,56	2,78	36,11	0	30,56

Canal 7

	ARRIBA	ABAJO	IZQUIERDA	DERECHA	CENTRO
ARRIBA	69,44	2,78	0	16,67	11,11
ABAJO	2,78	61,11	0	25	11,11
IZQUIERDA	19,44	5,56	27,78	22,22	25
DERECHA	19,44	0	27,78	41,67	11,11
CENTRO	5,56	8,33	0	13,89	72,22

Canal 8

	ARRIBA	ABAJO	IZQUIERDA	DERECHA	CENTRO
ARRIBA	66,67	22,22	0	5,56	5,56
ABAJO	2,78	38,89	41,67	16,67	0
IZQUIERDA	8,33	19,44	50	13,89	8,33
DERECHA	2,78	16,67	0	69,44	11,11
CENTRO	13,89	27,78	0	8,33	50

Canal 11

	ARRIBA	ABAJO	IZQUIERDA	DERECHA	CENTRO
ARRIBA	52,78	5,56	13,89	27,78	0
ABAJO	27,78	41,67	2,78	27,78	0
IZQUIERDA	16,67	13,89	44,44	25	0
DERECHA	0	8,33	2,78	72,22	16,67
CENTRO	5,56	11,11	16,67	30,56	36,11

Canal 12

	ARRIBA	ABAJO	IZQUIERDA	DERECHA	CENTRO
ARRIBA	66,67	2,78	11,11	19,44	0
ABAJO	33,33	36,11	0	30,56	0
IZQUIERDA	13,89	19,44	38,89	27,78	0
DERECHA	16,67	19,44	0	63,89	0
CENTRO	8,33	25	45,83	20,83	0

ANEXO 11. CARACTERÍSTICAS GENERALES DE LA HERRAMIENTA.

La aplicación llamada eegmove, se invoca para su ejecución con el módulo entrada y este abre una ventana, con el entorno grafico descrito en la figura 23. Desde esta ventana se selecciona si se va a realizar un entrenamiento o una verificación de datos. Para empezar el proceso, se escoge la opción principal que carga la interfaz mostrada en la figura 24, la cual posee en su menú principal las siguientes opciones: Archivo, Preprocesar, Clasificar y Ayuda, cada una de estas

permite entrar a los módulos específicos para el entrenamiento y procesamiento de los datos.

En primera instancia cuando se despliega el menú *Archivo*, este muestra otro submenú el cual contiene las siguientes elementos *Abrir, Salvar, Preferencia y salir*, En el submenú *Abrir* se encuentran los siguientes elementos Variable Matlab, Canal1, Canal2, Archivos .Mat. La opción Variable Matlab abre una ventana donde se permite leer una variable desde el entorno de trabajo de matlab, Los enlaces de los menús *Canal1* y *Canal2* permite cargar archivos de las señales provenientes de EEG que han sido tomadas de los participantes en las pruebas y salvadas en formato txt, el enlace del submenú *Archivo .mat*, permite cargar archivos con dicha extensión que contengan las diferentes variables como resolución, frecuencia de muestreo y demás previamente salvadas de un análisis anterior usando el enlace del primer submenú llamado *Salvar*. En el enlace del submenú *Preferencia* se determina la frecuencia de la tasa de muestreo que el usuario considere para trabajar, equivalente a la frecuencia en que se tomaron las muestras del EEG, de forma predeterminada el valor es 512 Hz, el último enlace del submenú Archivo es la opción *Salir* que permite cerrar la aplicación.

En segunda instancia cuando se abre el enlace del menú *Preprocesar* se genera un submenú el cual contiene los siguientes elementos: *Definir Wavelet, Definir Rna, Aplicar Wavelet y Aplicar Rna*. En el primer submenú *Definir Wavelet* abre una ventana donde se elige el tipo de wavelet a usar, teniendo disponible las familias Sym3, Sym6 o Db4 así como la resolución que se requiere en dicho análisis. Al aplicar el submenú *Definir Rna* aparece una ventana donde se pueden establecer los parámetros de la red neuronal: Nombre del archivo de clases, Nombre del Archivo de Patrones, Número de Patrones, Número de Neuronas Ocultas y Número de Clases. El submenú *Aplicar Wavelet* realiza el análisis wavelet propiamente dicho. El submenú *Aplicar Rna* ejecuta la red neuronal con los parámetros anteriormente definidos.

En tercera instancia cuando se escoge la opción del menú *Clasificar* muestra un submenú llamado *Respuesta del Mouse*, el cual hace el llamado al módulo de verificación con la interfaz mostrada en la figura 25, allí se puede observar la respuesta en modo grafico del movimiento del mouse, Este modulo posee cuatro botones que permitirán activar las funciones: *Cargar Entrenamiento*, la cual carga un archivo previamente procesado y listo para ejecución. *Cargar Vector*, selecciona una vector de una señal sin procesar para la comprobación del movimiento. *Mover* que ejecuta uno de los archivos cargados previamente en los botones anteriores y ejecuta el movimiento automático del mouse. *Salir* que cierra la aplicación. La ventana de este modulo tiene un entorno gráfico que muestra según el tipo de señal, la respuesta del movimiento coloreando un recuadro, También tiene un cuadro de texto que indica si la señal no clasifica dentro de los parámetros mínimos preestablecidos por el programa.

Como última instancia cuando se abre el enlace de menú *Ayuda* el cual contiene el submenú *Acerca de*, el cual al activarse, muestra una ventana con la información correspondiente al diseño de la aplicación.

Retomando el modulo principal de la aplicación, ésta posee los siguientes elementos: Un botón llamado *Graficar Entradas*, el cual grafica la señal a la cual se han seleccionado por medio de uno de los canales (canal 1 y canal 2), los cuales se visualizan en la parte superior del lado izquierdo del panel principal. Luego dos cuadros de texto llamados *Ventana de Análisis* donde podemos recortar la señal de muestra a procesar y así describir desde donde inicia y termina la muestra. Un botón llamado *Salvar Variable* el cual guarda archivos procesados con extensión txt. Dos cuadros de texto donde se introduce los índices de aproximación y detalle correspondientes a las características de la wavelet. Un botón que llamado *Graficar Wavelets* el cual muestra de manera grafica las respuestas de los canales previamente cargados (canal 1 y canal 2), los cuales se

visualizan en la parte inferior del lado izquierdo del panel principal. También se tiene un cuadro de texto donde puede introducirse el nombre de archivo que se quiera guardar. El botón *Salvar Patrón* el cual guarda el archivo definido en el cuadro texto en extensión txt. Un cuadro de texto donde se carga la resolución de la wavelet que se quiere visualizar con la opción de graficar wavelet. Se tienen seis recuadros donde se grafican las señales de los canales 1 y 2, además las graficas de procesamiento wavelet de estos mismo canales.